

**РОССИЙСКАЯ АКАДЕМИЯ НАУК
ВЫЧИСЛИТЕЛЬНЫЙ ЦЕНТР
при поддержке
РОССИЙСКОГО ФОНДА ФУНДАМЕНТАЛЬНЫХ ИССЛЕДОВАНИЙ**

**МАТЕМАТИЧЕСКИЕ МЕТОДЫ
РАСПОЗНАВАНИЯ ОБРАЗОВ
(ММРО-11)**

Доклады 11-й Всероссийской конференции

Москва
2003

Оргкомитет

- Председатель:** Журавлев Юрий Иванович, *академик РАН*
Зам. председателя: Лахно Виктор Дмитриевич, *д.ф.-м.н.*
Дюкова Елена Всеволодовна, *д.ф.-м.н.*
Ученый секретарь Воронцов Константин Вячеславович, *к.ф.-м.н.*
Члены: Донской Владимир Иосифович, *д.ф.-м.н.*
Дедус Флоренц Федорович, *д.т.н.*
Жданов Сергей Александрович, *к.ф.-м.н.*
Местецкий Леонид Моисеевич, *д.т.н.*
Немирко Анатолий Павлович, *д.ф.-м.н.*
Устинин Михаил Николаевич, *к.ф.-м.н.*
Махортых Сергей Александрович, *к.ф.-м.н.*

Программный оргкомитет

- Председатель:** Рудаков Константин Владимирович, *член-корр. РАН*
Зам. председателя: Матросов Виктор Леонидович, *член-корр. РАН*
Ученый секретарь Чехович Юрий Викторович
Члены: Микаэлян Андрей Леонович, *академик РАН*
Савин Геннадий Иванович, *академик РАН*
Сергиенко Иван Васильевич, *академик НАН Украины*
Жижченко Алексей Борисович, *член-корр. РАН*
Сойфер Виктор Александрович, *член-корр. РАН*
Моттль Вадим Вячеславович, *д.ф.-м.н.*
Пытьев Юрий Петрович, *д.ф.-м.н.*
Рязанов Владимир Васильевич, *д.ф.-м.н.*
Сенько Олег Валентинович, *к.ф.-м.н.*

Технический оргкомитет

- Председатель:** Громов Андрей Николаевич
Члены: Дурова Валентина Владимировна
Инякин Андрей Сергеевич
Кирсанов Антон Андреевич
Куликова Людмила Ивановна
Ольшевец Максим Максимович
Панкратов Антон Николаевич
Песков Николай Владимирович
Рейер Иван Александрович
Сычев Вячеслав Викторович
Юдаева Светлана Викторовна

I. Математическая теория распознавания

О групповых процедурах классификации распределений

Парето

Р.А. Абусев

(Пермь)

Введение

Имеются два подхода для решения статистических задач: классический подход, основанный на модели “поштучного” выбора объектов из совокупности, и более общий подход, основанный на модели группового выбора. Для примера рассмотрим две широко известные задачи из теории классификации и теории надежности.

Пусть совокупность π_i имеет плотность распределения $p(x|\theta_i)$, $i=1,2$, и x – произвольный заданный объект из $\pi_1 \cup \pi_2$. Тогда классический метод распознавания X (поточечная классификация) состоит

$$x \in \pi_1, \text{ если } p(x|\theta_1) \geq cp(x|\theta_2).$$

Аналогично, вероятность $P(Y>X)$ является важной характеристикой в теории надежности, когда X и Y независимые случайные величины (X – нагрузка, Y – прочность) с плотностями $p(x|\theta_1)$ и $p(y|\theta_2)$. В случае группового выбора, имеется группа $\pi_{00} = \{x_{01}, x_{02}, \dots, x_{0n_0}\}$ из какой-то одной совокупности π_i и $t_0 = t_0(x_{01}, x_{02}, \dots, x_{0n_0})$ является достаточной статистикой с плотностью условного распределения $p(t_0|\theta_i), i=1,2$. Тогда имеем более общее решающее правило (групповой классификации) $\pi_{00} \subset \pi_1$, если $p(t_0|\theta_1) \geq cp(t_0|\theta_2)$ в пространстве достаточной статистики t_0 .

В общем случае решающее правило групповой классификации строится на основе условных распределений

$$L(\pi_{00}|\theta_i) = \prod_{j=1}^{n_0} p(x_{0j}|\theta_i), i=1, 2.$$

Точно также, если $\pi_{00} = \{x_{01}, x_{02}, \dots, x_{0n_0}\}$ извлечена из распределения

$p(x|\theta_1)$, $\pi_{00}'' = \{y_{01}, y_{02}, \dots, y_{0n_0}\}$ - из распределения $p(y|\theta_2)$, t_0 и s_0 достаточные статистики для θ_1 и θ_2 , то более общей характеристикой в теории надежности будет вероятность $P(s_0 > t_0)$.

При этом, процедуры основанные на модели группового выбора обладают рядом существенных преимуществ:

1. Классические процедуры следуют из соответствующих групповых процедур при $n_0 = 1$.
2. Групповые процедуры позволяют существенно расширить априорную информацию за счет включения π_{00} в процесс оценивания и построения решающих правил.
3. Групповые процедуры позволяют уменьшить вероятность ошибочных выводов.

В данной статье решаются задачи статистического оценивания и групповой классификации для распределений Парето с плотностью

$$p(x|\lambda, \theta) = \frac{\theta \lambda^\theta}{x^{\theta+1}}, \quad x \geq \lambda, \lambda > 0; \theta > 0. \quad (1)$$

Если $\pi_{00} = \{x_{01}, x_{02}, \dots, x_{0n_0}\}$ извлечена из (1), то статистики

$$t_0 = x_{(1)} = \min\{x_{01}, x_{02}, \dots, x_{0n_0}\}, \quad s_0 = \sum_{j=1}^{n_0} \ln\left(\frac{x_{0j}}{t_0}\right) \quad \text{являются}$$

полными достаточными статистиками для λ, θ и имеют совместную плотность

$$p(t_0 s_0 | \lambda, \theta) = \frac{n_0 \theta^{n_0} \lambda^{n_0 \theta} s_0^{n_0 - 2} e^{-\theta s_0}}{\Gamma(n_0 - 1) t_0^{n_0 \theta + 1}}, \quad t_0 \geq \lambda, s_0 \geq \theta. \quad (2)$$

Кроме того, имеем выражение

$$L(\pi_{00} | \lambda, \theta) = \prod_{j=1}^{n_0} p(x_{0j} | \lambda, \theta) = \frac{\theta^{n_0} \lambda^{n_0 \theta}}{\prod_{j=1}^{n_0} x_{0j}^{\theta+1}} \quad (3)$$

для функции правдоподобия.

Групповая классификация

Пусть даны две совокупности π_i имеющие распределения Парето с условными плотностями $p(x|\lambda_i, \theta_i), i=1,2$. Пусть π_{00} извлечена из одной из них. Требуется классифицировать группу π_{00} . Предположим, что параметры λ_i, θ_i известны $i=1,2$. Тогда в соответствии с леммой Неймана-Пирсона можно строить оптимальное правило групповой классификации, используя выражения для $p(t_0, s_0|\lambda_i, \theta_i), i=1,2$

$$\pi_{00} \subset \pi, \text{ если } \frac{\theta_1^{n_0} \lambda_1^{n_0 \theta_1}}{\theta_2^{n_0} \lambda_2^{n_0 \theta_2}} t_0^{n_0(\theta_2 - \theta_1)} e^{-(\theta_1 - \theta_2)S_0} \geq c. \quad (4)$$

Для построения статистических решающих правил строятся различные статистические оценки для условных плотностей (2), (3) используя обратные выборки $\pi_{i0} = \{x_{i1}, x_{i2}, \dots, x_{in_i}\}, i=1,2$. Например, несмещенная оценка $\hat{p}(t_0, s_0|\lambda_i, \theta_i)$ для $p(t_0, s_0|\lambda_i, \theta_i)$ при неизвестных параметрах λ_i, θ_i дается формулой

$$\begin{aligned} \hat{p}(t_0 s_0|\lambda_i, \theta_i) &= \frac{n_0}{(n_i + n_0)t_0} \delta(\ln t_0 - \ln t_{n_i + n_0}) + \\ &+ \frac{n_0 n_i \Gamma(n_i + n_0 - 1) s_0^{n_0 - 2} [s_{n_i + n_0} - s_0 - n_0 \ln \frac{t_0}{t_{n_i + n_0}}]^{n_i - 2}}{(n_i + n_0) \Gamma(n_0 - 1) \Gamma(n_i - 1) t_0 s_{n_i + n_0}^{n_i + n_0 - 2}}, \end{aligned} \quad (5)$$

где $t_{n_i + n_0} = \min\{t_0, t_{n_i}\}, t_{n_i} = \min\{x_{i1}, x_{i2}, \dots, x_{in_i}\},$

$$s_{n_i} = \sum_{j=1}^{n_i} \ln\left(\frac{x_{0j}}{t_{n_i}}\right); s_{n_i + n_0} = \sum_{j=1}^{n_i} \ln\left(\frac{x_{ij}}{t_{n_i + n_0}}\right) + \sum_{j=1}^{n_0} \ln\left(\frac{x_{0j}}{t_{n_i + n_0}}\right), i=1,2.$$

На основе оценок (5) получим статистическое правило групповой классификации

$$\pi_{00} \subset \pi_1, \text{ если } \frac{\hat{p}(t_0 s_0|\lambda_1 \theta_1)}{\hat{p}(t_0 s_0|\lambda_2 \theta_2)} \geq c \quad (6)$$

объектов из распределений Парето. Аналогично, статистические решающие правила строятся, используя оценки максимального правдоподобия, несмещенные и байесовские оценок для (2), (3). Исследованы свойства

оценок и правил. Проведено качественное сравнение оценок и решающих правил аналитическими методами и методом моделирования. В частности, найдены аналитические выражения для квадратических погрешностей оценок и доказана асимптотическая оптимальность решающего правила (6).

Работа выполнена при финансовой поддержке РФФИ, грант №01-01-00494.

Об использовании баз знаний для повышения интеллектуальности систем распознавания

К.Р. Айда-заде, Дж.З. Гасанов, Э.Э. Мустафаев

(Азербайджан, Баку)

Одним из источников повышения эффективности и надежности систем распознавания образов является увеличение уровня интеллектуальности системы за счет использования баз знаний соответствующей конкретной предметной области. Современные технологии распознавания за счет тонкой настройки на конкретное применение позволяют с высокой надежностью определять объекты определенного класса. Однако применение этих систем в новых изменяющихся условиях, а именно для работы с объектами, несколько отличающихся от обучающихся выборок не позволяет достигать данного высокого уровня распознавания, т.к. не обладают достаточными средствами для настройки распознавания в процессе эксплуатации. Создание открытых обучающихся систем распознавания на основе пополняемых в процессе эксплуатации баз знаний и имевшихся место специфических ситуаций при распознавании позволило бы существенно увеличить эффективность систем.

Создание данных систем подразумевает наличие следующих свойств:

- возможность пополнения базы знаний согласно результатам распознавания;
- анализ результатов распознавания по данным в базе знаний и возможность переобучения системы;
- использование баз знаний непосредственно в процессе распознавания;

На этапе создания системы в нее закладываются базы знаний с информацией о различных областях. В процессе эксплуатации система позволяет создавать и накапливать информацию в базе знаний для конкретной предметной области. Пользователь также имеет возможность по собственной инициативе пополнять и редактировать базы. В процессе эксплуатации системы также происходит сохранение результатов распознавания для дальнейшего анализа. При этом сохраняется информация о некорректно распознанных символах, ее частотность и информацию о графическом образе, полученную при помощи применяемых в системе

различных алгоритмов извлечения признаков.

В процессе эксплуатации система имеет возможность анализа данных, накопленных в базе знаний, и на ее основе автоматического принятия решения на переобучение. При этом происходит более тонкая настройка системы и адаптация ее к конкретному пользователю. Происходит анализ и пополнение информации для данной предметной области. Например, применительно к распознаванию рукописно заполненных форм эта процедура существенно повышает качество распознавания для систем рукописного ввода и автоматического ввода рукописных форм, т.к. именно рукописное написание характеризуется многообразием форм начертания и требует более точной настройки на конкретный подчёрк. Отметим, что переобучение производится не для всей системы, а только лишь для соответствующей подсистемы. Пользователь на данном этапе имеет возможность расширить алфавит распознаваемых образов, причем не только вводом одного символа, а также увеличить число классов. Это может привести к тому, что различные прообразы (изображения) будут относиться к одному образу и информация об этом будет указана в базе знаний.

Важным свойством данных систем является использование информации из баз знаний непосредственно в процессе распознавания, а не после нее, причем распознающий модуль и подсистема извлечения информации из баз знаний работают на одном уровне и имеют возможность циклической передачи данных друг другу. Информация о результатах точного и сомнительного распознавания символов передается в базу знаний. Подсистема работы с базой определяет возможные значения неточно найденных символов и передает эту информацию обратно в модуль распознавания. Такая модель распознавания дает значительный выигрыш в точности и надежности, особенно, при распознавании полей рукописных форм, т.к. значение поля может определяться точным распознаванием не всего поля, а лишь нескольких символов. Этот принцип распознавания более близок к естественному методу распознавания человека, т.к. чтение текста, как правило, происходит не по-буквенно (определением всех символов), а определением всего слова.

Предлагаемый выше подход к построению системы распознавания с использованием баз знаний был применен при разработке системы распознавания рукописных форм, что позволило существенно увеличить эффективность систем.

Литература

1. Бонгард М.М. Проблема узнавания // Наука, Москва, 1967.
2. Aida-zade K.R., Mustafayev E.E. On a hierarchical handwritten forms recognition system on the basis of the neural networks // Conference material of TAINN 2003 (International XII Turkish Symposium on Artificial Intelligence and Neural Networks), Canakkale, Turkey, 2003.

Структурный подход к построению групповых классификаций

М.Б. Айдарханов
(Алматы)

Представление классификаций конечного множества объектов в единичном кубе

В последнее время в задачах классификации широко применяются групповые методы заключающиеся в синтезе принимаемого решения из результатов работы множества исходных алгоритмов.

В [1,2] были предложены структурный и метрический подход к решению задачи группового синтеза классификаций. В данной работе определено представление классификаций конечного множества объектов в единичном кубе, и предложен метод группового синтеза, основанный на координатных (базисных) представлениях классификаций.

Пусть $M = \{S_1, \dots, S_n\}$ - конечное множество объектов. Классификацией множества M будем называть его разбиение на попарно непересекающиеся подмножества (классы) $K_i(M)$. Пусть $K(M)$ пространство классификаций (разбиений) множества M . Определим на нем операцию \vee следующим образом: пусть $K, K' \in K(M)$ тогда, $S(K \vee K')S'$ означает, что для подходящих S^0, S^1, \dots, S^t где $S^0 = S, S^t = S'$ и для любого $i = 0, 1, \dots, t-1$ справедливо $S^i R S^{i+1}$ или $S^i R' S^{i+1}$ где R, R' - отношения эквивалентности, соответствующие классификациям K, K' .

Обозначим через $K^l(M)$ множество классификаций M на $l, 1 \leq l \leq n$ классов, через $K(u, v)$ классификацию из $K^{n-1}(M)$, в которой объекты $S_u, S_v, u \neq v$, принадлежат одному классу. Для определенности считаем, что $v > u$. Пусть

$$T = \{K(u_1, v_1), \dots, K(u_t, v_t)\}.$$

Определение 1. T называется допустимым, если $(u_i \neq u_j) \wedge (v_i \neq v_j)$, для $i \neq j, i, j = 1, 2, \dots, t$.

Пусть K - произвольная классификация из $K(M), K = \{K_1, \dots, K_l\}$, где K_1, \dots, K_m - классы классификации K . Без ограничения общности будем полагать, что

$$K_{j+1} = \{S_{n_j+1}, \dots, S_{n_{j+1}}\}, \quad j = 0, \dots, l-1, \quad 2 \leq l \leq n, \quad n_0 = 0, \quad n_l = n.$$

Тогда K поставим в соответствие следующее допустимое множество

$$T(K) = \bigcup_{j=1}^l \bigcup_{i=1}^{|K_j|-1} \{K(n_{j-1} + i, n_{j-1} + i + 1)\}.$$

Пусть

$$V = \{(1,2), (1,3), \dots, (1,n), (2,3), \dots, (2,n), \dots, (n-1,n)\}.$$

Зафиксируем этот порядок расположения пар и перенумеруем их.

Определим булевский набор $\tilde{\alpha}(K) \in E^N$ следующим образом

$$\tilde{\alpha}(K) = \langle \alpha_{(1,2)}, \dots, \alpha_{(1,n)}, \dots, \alpha_{(n-1,n)} \rangle = \langle \alpha_1, \dots, \alpha_N \rangle, \quad N = C_n^2$$

$$\alpha_{(u,v)} = \begin{cases} 1, & \text{если } K(u,v) \in T(K) \\ 0, & \text{если } K(u,v) \notin T(K) \end{cases}.$$

$$\text{Тогда имеем } K = \bigvee_{(u,v) \in V} \alpha_{(u,v)} K(u,v)$$

Таким образом, каждой классификации $K \in \mathbf{K}(M)$ однозначно соответствует координатное представление в базисе $\mathbf{K}^{n-1}(M)$ через набор $\tilde{\alpha}(K) = \langle \alpha_1(K), \dots, \alpha_N(K) \rangle$ размерности N . Данное двоичное представление классификаций позволяет ввести в пространстве классификаций $\mathbf{K}(M)$ метрику, индуцированную метрикой Хемминга в единичном кубе E^N . Обозначим ее через d . Область единичного куба в которую отображается пространство классификаций двоичным представлением назовем допустимой и будем обозначать E_0^N .

Теорема 1. Вес набора $\tilde{\alpha}(K)$, где $K \in K^l(M)$, $1 \leq l \leq n-1$, $|M| = n$ равен $n-l$ ($\|\tilde{\alpha}(K)\| = n-l$).

Метод группового синтеза, основанный на координатных представлениях классификаций

Пусть A_1, \dots, A_m - алгоритмы решения задачи классификации на множестве M и $K_1, \dots, K_m \in \mathbf{K}(M)$ - соответствующие им классификации, полученные в результате их применения к исходной задаче.

Определение 2. Пусть $K_1, \dots, K_m \in K(M)$. Тогда K^* называется групповой, если на ней достигается минимум функционала

$$\Phi(K) = \sum_{i=1}^m d(K, K_i), \text{ то есть } \Phi(K^*) = \min_{K \in K(M)} \Phi(K).$$

Пусть $\tilde{\alpha}(K_i) = \langle \alpha_1(K), \dots, \alpha_N(K) \rangle$ - координатное представление классификации K_i полученной алгоритмом A_i , $i = 1, \dots, m$. Тогда задача группового синтеза сводится к нахождению K^* такой, что

$$\sum_{i=1}^m d_0(\tilde{\alpha}(K^*), \tilde{\alpha}(K_i)) = \min_{K \in K(M)} d_0(\tilde{\alpha}(K), \tilde{\alpha}(K_i)), \text{ где } d_0 - \text{ метрика Хемминга.}$$

Определим кортеж $\tilde{\alpha}^* = \langle \alpha_1, \dots, \alpha_N \rangle \in E^N$ следующим образом:

$$\alpha_j = 1, \text{ если } \sum_{i=1}^m \alpha_j(K_i) > m/2; \quad \alpha_j = 0 \text{ в противном случае,}$$

$$j = 1, \dots, N.$$

Теорема 2. $\tilde{\alpha}^*$ принадлежит E_0^N и является решением задачи группового синтеза классификаций т.е.

$$\sum_{i=1}^m d_0(\tilde{\alpha}^*, \tilde{\alpha}(K_i)) = \min_{K \in K(M)} d_0(\tilde{\alpha}(K), \tilde{\alpha}(K_i)).$$

Литература

1. Айдарханов М.Б. Метрический и структурный подходы к построению групповых классификаций // Гылым, Алматы, 1994. 56 с.
2. M. B. Aidarkhanov Metric and Structural Approaches to the Construction of Group Classifications // Pattern Recognition and Image Analysis. – 1994 – Vol.4, N 4. P. 372-389

Вычисления стационарных точек плотности вероятностей гауссовой смеси

Н.Н. Апраушева, Н. Моллаверди, С.В. Сорокин, А.Е. Торхов
(Москва)

Актуальность проблемы определения мод гауссовой смеси обусловлена их широким использованием в различных областях науки и практики [1, 2]. В некоторых публикациях, например в [2], для решения этой задачи предложены алгоритмы, базирующиеся на известных итеративных методах, но не обоснованные строго математически.

В этом докладе представлен математически обоснованный алгоритм вычисления всех стационарных точек (СТ) плотности вероятностей $f(x)$ простейшей гауссовой смеси,

$$f(x) = (\sqrt{2\pi}\sigma)^{-1} \sum_{i=1}^k \pi_i \exp\left(-\frac{(x - \mu_i)^2}{2\sigma^2}\right), \quad (1)$$

где $2 \leq k < \infty$, μ_i – вектор математического ожидания i -ой компоненты, π_i – её априорная вероятность, σ^2 – дисперсия каждой компоненты, $x \in R$, $R = (-\infty, +\infty)$,

$$\pi_i \in (0, 1) \quad \sum_{i=1}^k \pi_i = 1.$$

Параметры распределения смеси $\pi_1, \pi_2, \dots, \pi_k, \mu_1, \mu_2, \dots, \mu_k, \sigma^2$ – известны. Для определённости положим

$$\mu_1 < \mu_2 < \dots < \mu_k$$

Стационарные точки функции $f(x)$ – это корни уравнения

$$f'_x(x) = 0,$$

которое приводится к равносильному уравнению

$$x = \varphi(x), \quad (2a)$$

$$\varphi(x) = \left[\sum_{i=1}^k \pi_i \mu_i \exp\left(-\frac{(x - \mu_i)^2}{2\sigma^2}\right) \right] \cdot \left[\sum_{i=1}^k \pi_i \exp\left(-\frac{(x - \mu_i)^2}{2\sigma^2}\right) \right]^{-1}. \quad (2b)$$

Доказаны следующие полезные свойства оператора φ .

1. Все неподвижные точки (НТ) оператора φ лежат в интервале (μ_1, μ_k) .
Если оператор φ имеет одну НТ, то она является модой функции $f(x)$.

2. Оператор φ является непрерывным, монотонно возрастающим и ограниченным на всей числовой прямой R , причём

$$\lim_{x \rightarrow -\infty} \varphi(x) = \mu_1, \quad \lim_{x \rightarrow \infty} \varphi(x) = \mu_k.$$

3. Оператор φ отображает отрезок $[\mu_1, \mu_k]$ в себя. Последовательность, итераций Пикара [3, 4]

$$x_n = \varphi(x_{n-1}), \quad n = 1, 2, \dots, \quad x_0 \in [\mu_1, \mu_k], \quad (3)$$

сходится к тем НТ оператора φ , которые являются модами или точками перегибов функции $f(x)$.

Для вычисления точек локальных минимумов (ЛМ) функции $f(x)$ используется уравнение

$$x = \zeta(x), \quad (4a)$$

$$\zeta(x) = (1 + \lambda)x - \lambda \varphi(x), \quad (4b)$$

$$\lambda = 4 \left(\sum_{s>i} \rho_{si}^2 \right)^{-1}, \quad s = 2, 3, \dots, k, \quad i = 1, 2, \dots, k-1, \quad (4c)$$

где ρ_{si} – расстояние Махаланобиса, $\rho_{si} = (\mu_s - \mu_i) \sigma^{-1}$. Уравнение (4) равносильно уравнения (2).

Оператор ζ обладает следующими заданными свойствами:

1. Оператор ζ является непрерывным, монотонно возрастающим и неограниченным на всей числовой прямой R .

2. Оператор ζ отображает в себя отрезок $[x_1^*, x_m^*]$, где m – число мод функции $f(x)$, $2 \leq m \leq k$, x_1^*, x_m^* – моды $f(x)$, $x_1^* < x_2^* < \dots < x_m^*$.

3. Последовательность итераций Пикара

$$x_n = \zeta(x_{n-1}), \quad n = 1, 2, \dots, \quad x_0 \in [x_1^*, x_k^*], \quad (5)$$

сходится к тем НТ оператора ζ , которые являются точками минимумов или перегибов функции $f(x)$.

Алгоритм вычисления СТ функции $f(x)$ состоит из чередования использования последовательностей (3) и (5) для мультимодальной смеси и использования только последовательности (3) в случае её унимодальности, которую алгоритм обнаруживает автоматически.

Алгоритм был апробирован на многочисленных экспериментах, результаты некоторых из них приведены ниже. Исследовалось 5 смесей при

$k = 4$, $\sigma^2 = 1$ и различных значениях остальных параметров, данных в табл. 1.

Таблица 1.

N смеси	Параметры смесей							
	Средние значения				Априорные вероятности			
	μ_1	μ_2	μ_3	μ_4	π_1	π_2	π_3	π_4
1	0.00	5.00	11.00	16.00	0.15	0.45	0.25	0.15
2	0.00	3.00	6.00	9.00	0.25	0.25	0.25	0.25
3	0.00	2.00	4.00	8.00	0.25	0.05	0.45	0.25
4	0.00	2.00	4.00	6.00	0.45	0.25	0.05	0.25
5	0.00	2.00	4.00	6.00	0.10	0.70	0.15	0.05

Значения СТ этих смесей, вычисленные по разработанному алгоритму, представлены в табл. 2 (ЛМ – точки локальных минимумов функции $f(x)$).

Таблица 2.

N смеси	СТ функции $f(x)$						
	Моды				ЛМ		
	x_1^*	x_2^*	x_3^*	x_4^*	\check{x}_1	\check{x}_2	\check{x}_3
1	0.00	5.00	11.00	16.00	2.24	8.11	13.62
2	0.04	3.00	6.00	8.96	1.50	4.50	7.50
3	0.06	3.97	8.00		1.76	6.20	
4	0.20	5.94			4.00		
5	2.02						

Из данных таблиц 1, 2 следует, что при фиксированных значениях k и σ^2 число мод смеси m зависит от значений $\mu_1, \mu_2, \dots, \mu_k, \pi_1, \pi_2, \dots, \pi_k, 1 \leq m \leq 4$.

Литература

1. Волошин Т.Я., Бурлаков И.А., Косенкова С.Т. Статистические методы решения задач распознавания, основанные на аппроксимационном подходе. Владивосток, 1996.
2. Carreira-Perpóñán M.A. Mode-finding for Mixture of Gaussian Distributions. IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol. 22, № 11, pp. 1318-1323, 2000.
3. Немыцкий В.В. Метод неподвижных точек в анализе. Успехи математических наук. М.-Л.: 1936, вып. 1.
4. Хатсон В., Пим Дж. Приложение функционального анализа и теория операторов. М.: Мир, 1983.

Об условиях унимодальности простейшей гауссовой смеси

Н.Н. Апраушева, С.В. Сорокин

(Москва)

Конечные гауссовы смеси нашли широкое применение в различных областях науки и практики [1, 2]. Популярность конечных гауссовых смесей вызывает необходимость решения таких задач как определение мод и предварительное оценивание их числа, связанное со свойством унимодальности. В общем случае условия унимодальности гауссовой смеси не найдены, они получены лишь для некоторых частных случаев, преимущественно для двухкомпонентных смесей [2].

В этом докладе даны четыре достаточных условия унимодальности простейшей гауссовой смеси, функция плотности вероятностей которой имеет вид:

$$f(x) = (\sqrt{2\pi}\sigma)^{-1} \sum_{i=1}^k \pi_i \exp\left(-\frac{(x - \mu_i)^2}{2\sigma^2}\right), \quad (1)$$

где $2 \leq k < \infty$, μ_i – вектор математического ожидания i -ой компоненты, π_i – её априорная вероятность, σ^2 – дисперсия каждой компоненты, $x \in R$, $R = (-\infty, +\infty)$,

$$\pi_i \in (0, 1) \quad \sum_{i=1}^k \pi_i = 1.$$

Параметры распределения в (1) $\pi_1, \pi_2, \dots, \pi_k, \mu_1, \mu_2, \dots, \mu_k, \sigma^2$ известны. Для определённости положим

$$\mu_1 < \mu_2 < \dots < \mu_k$$

Мода функции $f(x)$ является корнем уравнения

$$f'_x(x) = 0, \quad (2)$$

которое приводится к равносильному уравнению

$$x = \varphi(x), \quad (3a)$$

$$\varphi(x) = \frac{\left[\sum_{i=1}^k \pi_i \mu_i \exp\left(-\frac{(x - \mu_i)^2}{2\sigma^2}\right) \right]}{\left[\sum_{i=1}^k \pi_i \exp\left(-\frac{(x - \mu_i)^2}{2\sigma^2}\right) \right]}. \quad (3b)$$

Известно [3, 4], что сжимающий оператор на отрезке $[\mu_1, \mu_k]$ имеет

только одну неподвижную точку и что если φ – сжимающий оператор на отрезке $[\mu_1, \mu_k]$, то для всех $x \in [\mu_1, \mu_k]$ выполняются следующие условия:

$$\mu_1 \leq \varphi(x) \leq \mu_k,$$

$$|\varphi(x_2) - \varphi(x_1)| \leq \alpha |x_2 - x_1|, \quad 0 < \alpha < 1, \quad x_1, x_2 \in [\mu_1, \mu_k].$$

Следовательно, отыскание условий унимодальности функции $f(x)$ сводится к отысканию условий, при которых оператор φ является сжимающим. Отметим, что оператор φ является функцией.

Доказаны следующие теоремы.

1. Все неподвижные точки оператора φ лежат в интервале (μ_1, μ_k) . Если оператор φ имеет одну неподвижную точку, то она является модой функции $f(x)$.

2. Оператор φ является непрерывным, монотонно возрастающим и ограниченным на всей числовой оси R , он отображает отрезок $[\mu_1, \mu_k]$ в себя.

3. Оператор φ на отрезке $[\mu_1, \mu_k]$ является сжимающим, а функция $f(x)$ – унимодальной, если

$$\varphi'_x(x) < 1$$

для всех $x \in [\mu_1, \mu_k]$.

4. При $k = 2$, оператор φ является сжимающим на отрезке $[\mu_1, \mu_k]$, а функция $f(x)$ – унимодальной, если

$$\rho^2 \leq 4,$$

где ρ^2 – расстояние Махаланобиса, $\rho = \rho_{21}$,

$$\rho_{21} = (\mu_2 - \mu_1) \sigma^{-1}.$$

5. При $k = 2$, $\rho^2 > 4$ и $\pi_1 \neq \pi_2$ оператор φ является сжимающим на отрезке $[\mu_1, \mu_2]$, а функция $f(x)$ – унимодальной, если

$$\left| \ln(\pi_1 \pi_2^{-1}) \right| \geq 2^{-1} \rho^2 + 2 \ln(2^{-1}(\rho + \sqrt{\rho^2 - 4})), \quad \pi_1 \neq \pi_2.$$

6. При $k = 2$ и $\pi_1 = \pi_2$ точка $\tilde{x} = 2^{-1}(\mu_1 + \mu_2)$ является неподвижной точкой оператора φ . Если $\rho^2 \leq 4$, то \tilde{x} – мода функции $f(x)$, если $\rho^2 > 4$, то \tilde{x} – точка минимума бимодальной функции $f(x)$.

7. При $k \geq 3$ оператор φ на отрезке $[\mu_1, \mu_k]$, является сжимающим, а функция $f(x)$ – унимодальной, если

$$\rho_{k1}^2 \leq 4, \quad \max_{\rho_{si} \in P} \rho_{si}^2 \leq 2,$$

$$\rho_{si} = (\mu_s - \mu_i) \sigma^{-1},$$

$$P = \{\rho_{si}, s > i\} \setminus \rho_{k1}, \quad s = 2, 3, \dots, k, \quad i = 1, 2, \dots, k-1.$$

8. При $k \geq 3$ и $\rho_{k1}^2 > 4$ оператор φ на отрезке $[\mu_1, \mu_k]$ является сжимающим, а функция $f(x)$ унимодальной, если

$$\max_s \rho_{s,s-1}^2 \leq 2, \quad s = 2, 3, \dots, k, \quad \rho_{k1}^2 < 4 + \Delta\rho^*,$$

$$\Delta\rho^* = (\pi_k \pi_1)^{-1} \pi_{max}^2 (k + k^* (2 - \rho_{min}^2)),$$

где $\pi_{max} = \max \pi_i, i = 1, 2, \dots, k, \rho_{min} = \min \rho_{si}, \rho_{si} \in P, k^* -$ число элементов $\rho_{si}^2 \leq 2, \rho_{si} \in P.$

Из теоремы 8 следует, что верхняя граница $\rho_{k1}^* = (4 + \Delta\rho^*)^{1/2}$ тех значений ρ_{k1} , при которых простейшая гауссова смесь унимодальна, является возрастающей функцией параметра k .

Литература

1. Titterington D.M., Smith A.F., Markov U.E. Statistical Analysis of Finite Mixture Distributions. Chichester, New York, Brisbane, Toronto, Singapore. 1987.
2. Carreira-Perpinan M.A. Mode-finding for mixtures of Gaussian distributions. Technical Report CS-99-03, University of Sheffield UK, 1999.
3. Колмогоров А.Н., Фомин С.В. Элементы теории функций и функционального анализа. М.: Наука, 1972.
4. Алимов Ш.А. Принцип сжатых отображений. Новое в жизни, науке, технике. Сер. математика, кибернетика. М.: Знание, 1983, №5.

Методы стохастической аппроксимации в задачах кластерного анализа

Е.В. Бауман, А.А. Дорофеев
(Москва)

Классификационный анализ данных часто приходится производить по бесконечной выборке объектов. В таком случае актуальной задачей является разработка рекуррентных алгоритмов типа стохастической аппроксимации, в которых решающие функции классификации последовательно пересчитываются при появлении очередного объекта выборки. При такой постановке на каждом шаге алгоритма параметры решающих функций оцениваются некоторыми статистическими характеристиками классов

классификации. Наиболее распространенными статистическими характеристиками классов являются оценки ненормированных моментов классов. В соответствие с этим рассмотрим постановку задачи классификации с критерием, зависящим от ненормированных моментов классов.

Постановка задачи

1). В качестве классифицируемого множества будет рассматриваться множество X с заданной вероятностной мерой $P(A)$, ($A \subseteq X$).

2). Размытой классификацией множества X на r классов называется r -мерная вектор-функция $H(x) = (h_1(x), \dots, h_r(x))$ ($h_i(x)$ - функция принадлежности к i -му классу), удовлетворяющая условиям: во-первых, $h_i(x)$ - измеримы по мере P и, во-вторых, для любого $x \in X$ значение

$H(x)$ удовлетворяет условию нормировки $\sum_{i=1}^r h_i(x) = 1, 0 \leq h_i(x) \leq 1$.

3). Будем считать, что критерий качества классификации зависит от вероятностей и моментов классов. Для того, чтобы рассматривать моменты классов, вводится в рассмотрение вектор-функция $z(x)$ ($z : X \rightarrow Z = R^k$). Обычно пространство Z называют спрямляющим пространством, так как в нем все рассматриваемые моменты являются первыми). Предполагается, что 1) $\exists A > 0 : P(|z(x)| > A) = 0$, 2) $\forall c \in R^k$ и $\forall d \in R^1$ выполняется $P((c, z(x)) + d = 0) = 0$

Рассмотрим ненормированные моменты и вероятности классов

$$p_i = \int_X \varphi(h_i(x)) dP(x), \quad M_i = \int_X z(x) \varphi(h_i(x)) dP(x), i = 1, \dots, r.$$

Здесь $\varphi(h)$ - монотонно-возрастающая функция, отображающая отрезок $[0,1]$ на себя, причем $\varphi(0) = 0$ и $\varphi(1) = 1$. (Выбор функции $\varphi(h)$ дает возможность варьировать тип размытости оптимальной классификации [1]).

Обозначим $\mu(H) = (p_1, M_1, \dots, p_r, M_r)$ - $r(k+1)$ -мерный вектор, составленный из вероятностей и ненормированных моментов классов.

Критерий качества классификации, рассматриваемый в работе имеет следующий вид

$$\Phi(H) = \phi(\mu(H)),$$

где ϕ - выпуклая функция от $r(k+1)$ -мерного вектора $\mu(H)$.

Вид оптимальной классификации

Пусть задан вектор $r(k+1)$ -мерный вектор $\pi = (d_1, c_1, \dots, d_r, c_r)$, где $d_i \in R^1, c_i \in R^k, i = 1, \dots, r$. Назовем линейной с вектором коэффициентов π классификацию

$$H_\pi(x) = \arg \max_{(h_1, \dots, h_r): h_i \geq 0, \sum_{i=1}^r h_i = 1} \sum_{i=1}^r ((c_i, z(x)) + d_i) \varphi(h_i)$$

Лемма 1. Если π -субградиент функции ϕ в точке $\mu(H)$, то $\phi(\mu(H_\pi)) \geq \phi(\mu(H))$.

Из леммы следует, что оптимальная классификация должна быть линейной.

Рекуррентный алгоритм классификации

Цель настоящей работы - построить алгоритм максимизации функционала (1) по бесконечной выборке объектов $S = \{x_1, \dots, x_n, \dots\}$, появляющихся независимо в соответствии с законом распределения P .

На каждом шаге алгоритма по конечной подвыборке объектов $S_n = \{x_1, \dots, x_n\}$ для данной классификации $H(x) = (h_1(x), \dots, h_r(x))$ строятся оценки моментов и частоты (оценки вероятностей) классов

$$s_i = \frac{1}{n} \sum_{j=1}^n z(x_j) \varphi(h_i(x_j)), \quad v_i = \frac{1}{n} \sum_{j=1}^n \varphi(h_i(x_j)), \quad i = 1, \dots, r$$

Обозначим через $\psi(H)$ $r(k+1)$ -мерный вектор частот и оценок моментов классов.

Лемма 2. Для любых $\eta > 0$ и $\varepsilon > 0$ с вероятностью большей $1 - \eta$ одновременно для всех классификаций H выборки S_n выполняется неравенство

$$\phi(\mu(H_\pi)) \geq \phi(\psi(H)) - |\pi|D \left[2\varepsilon + \sqrt{\frac{r(k+1)}{2} \ln\left(\frac{4r(k+1)}{\varepsilon}\right) + \ln\left(\frac{2}{\eta}\right)} \right].$$

где π -субградиент функции ϕ в точке $\psi(H)$, а $D = const$.

Предлагаемый алгоритм при появлении новой точки x_n пересчитывает оценки моментов и определяет текущую классификацию множества X на

данном шаге. Формально он записывается следующим образом.

$$v_i^n = \frac{(n-1)v_i^{n-1} + \varphi(h_i^{n-1}(x_n))}{n}$$

$$s_i^n = \frac{(n-1)s_i^{n-1} + \varphi(h_i^{n-1}(x_n))F(x_n)}{n}, \psi^n = (v_1^n, s_1^n, \dots, v_r^n, s_r^n),$$

π^n - субградиент функции ϕ в точке ψ^n , $H^n = H_{\pi^n}$

Теорема 2. Если ϕ - выпуклая функция и все ее субградиенты ограничены, то в силу алгоритма с вероятностью единица справедливо:

$$\liminf_{n \rightarrow \infty} \Phi(H^n) \geq \lim_{n \rightarrow \infty} \Phi(\psi^n) = C(S), \text{ где } C(S) - \text{константа, зависящая}$$

от выборки S , являющаяся односторонне-стационарным значением функции ϕ , если кроме того ϕ - дважды непрерывно дифференцируемая функция, то $C(S)$ - стационарное значение функции ϕ и любая предельная точка последовательности $\{\psi^n\}$ является стационарной.

Литература

1. Бауман Е.В., Дорофеев А.А. Классификационный анализ данных //В сб.: "Избранные труды Международной конференции по проблемам управления. Том 1". М.: СИНТЕГ, 1999.

Задача оптимальной кусочной аппроксимации с использованием методов классификационного анализа

Е.В. Бауман, А.А. Дорофеев, Г.В. Корнилов
(Москва)

Основная идея кусочной аппроксимации сложной зависимости состоит в разбиении пространства входных показателей на такие области, в пределах каждой из которых сложную во всем пространстве функцию (зависимость) можно аппроксимировать простой функцией, например, линейной.

Рассматривается задача построения зависимости выходного показателя y от k -мерного вектора входных показателей $x \in X = \mathbf{R}^k$ по выборке из n объектов, каждый из которых описывается вектором $(y_t, x_t) \in \tilde{X} = \mathbf{R}^{k+1}$. Задача кусочно-линейной аппроксимации состоит в нахождении такой классификации $H = (H_1, \dots, H_r)$ пространства \mathbf{R}^k , такого k -мерного вектора коэффициентов \tilde{c}_i и константы d_i , чтобы функционал

$$I = \sum_{i=1}^r \sum_{x_t \in H_i}^n [y_t - ((c_i, x_t) + d_i)]^2 \quad (1) \text{ принимал минимальное значение [1].}$$

Классификацию H задают через вектор-функцию принадлежностей $(h_1(x), \dots, h_r(x))$.

Рассмотрено использование в задаче кусочной аппроксимации размытой классификации, когда $0 \leq h_i(x) \leq 1$, $\sum_{i=1}^r h_i(x) = 1$ (2). Тогда функционал (1)

$$\text{модифицируется: } I_2 = \sum_{i=1}^r \sum_{t=1}^n [y_t - ((c_i, x_t) + d_i)]^2 \varphi(h_i(x)) \quad (3), \text{ где } \varphi(h) -$$

монотонно возрастающая функция, определяющая тип размытости. Выделяется три типа размытости: 1) четкая классификация - $\varphi_1(h) = h$;

2) размытая классификация - $\varphi_2(h) = (h)^t, t > 1$; 3) классификацией с размытыми границами - $\varphi_3(h) = t - \sqrt{t^2 - (2t-1)h}, t > 1$. Для оптимизации функционала (3) используется общий итерационный алгоритм классификационного анализа данных [1]. Доказана сходимость этого алгоритма для такого вида функционалов [1].

Как и для четкой кусочной аппроксимации недостатком такого подхода является то, что в решающие правила аппроксимации входят не только входные показатели, но и выходной. Для того, чтобы избавиться от этого вводятся ограничения на класс решающих правил (классификаций). В прикладных работах кусочную аппроксимацию обычно строят так, чтобы классификация производилась по одному набору показателей, а аппроксимация в каждом классе - по другому [2]. В соответствии с этим, кроме пространства входных показателей X вводится пространство $Z = \mathbf{R}^s$, в котором и производится классификация объектов, при этом пространства X и Z могут пересекаться. Тогда каждый объект описывается $k + s + 1$ параметром, т.е. вектором (y_t, x_t, z_t) .

Обычно, критерий качества классификации – это средневзвешенная дисперсия точек в классах [1]. Для пространства Z он запишется в виде:

$$J = \sum_{i=1}^r \sum_{t=1}^n (z_t - \alpha_i)^2 \varphi(h_i(z_t)) \quad (4), \text{ где } \alpha_1, \dots, \alpha_r - \text{эталоны классов. Эталоны}$$

классов могут быть произвольными точками Z , вектор-функция $H(z)$ удовлетворяет условиям (2), а функция φ равна либо φ_1 , либо φ_2 , либо φ_3 .

Минимизация функционала (4) производится как по классификации $H(z)$, так и по набору эталонов классов $A = (\alpha_1, \dots, \alpha_r)$. Для оптимального

случая эталон i -го класса совпадает с центром соответствующего класса.

В итерационном алгоритме минимизации функционала (4) центральным является понятие эталонной классификации [1]. Эталонной называется классификация $H^A(z)$, доставляющая минимум критерию качества классификации при фиксированном наборе эталонов классов $A = (\alpha_1, \dots, \alpha_r)$.

Пусть определен вектор $A = (\alpha_1, \dots, \alpha_r)$. Тогда эталонная классификация $H^A(z) = (h_1^A(z), \dots, h_r^A(z))$ для каждого из трёх вариантов функции $\varphi(h)$ определяется однозначно. Ограничимся множеством эталонных классификаций пространства Z . Тогда задача сводится к минимизации функционала (3) или (4) для эталонной в пространстве Z классификации $H(x)$. В этом случае функционал (3) принимает вид:

$$I_2^A(A; c_i, d_i, i = 1, \dots, r) = \sum_{i=1}^r \sum_{t=1}^n [y_t - ((c_i, x_t) + d_i)]^2 \varphi(h_i^A(z_t)) \quad (5).$$

Функционал (5) дифференцируем по своим свободным параметрам, и для нахождения его экстремумов можно применять градиентные процедуры.

Недостаток локальной оптимизации - зависимость результата от начальных условий, поэтому актуальна разработка методов глобальной оптимизации. При фиксированном наборе эталонов классов $A = (\alpha_1, \dots, \alpha_r)$ по методу наименьших квадратов однозначно находятся коэффициенты линейных моделей классов $c_i, d_i, i = 1, \dots, r$, минимизирующие функционал (5). Таким образом, если можно перебрать все возможные наборы эталонов классов, то можно найти глобальный минимум выбранного функционала.

Выделим в Z некоторое конечное множество точек $Z_p = \{\beta_1, \dots, \beta_p\}$, только из которого можно выбирать эталоны классов. Число вариантов выбора различных эталонов будет равно p^r . Так как в прикладных задачах число классов в кусочной аппроксимации редко бывает больше пяти-шести, а число точек в Z_p можно взять порядка 100, то такой перебор вполне можно делать на современных ПЭВМ. В качестве множества Z_p можно взять, например, реализацию в пространстве Z исходной выборки объектов. В качестве Z_p можно взять также достаточно разреженную решетку в Z . Такой вариант хорошо использовать в качестве начальных условий для градиентного алгоритма без ограничения на набор эталонов.

Отдельно выделен случай одномерного пространства Z . Обычно считается, что в одномерной классификации могут перекрываться лишь соседние классы, поэтому на эталонную классификацию

$H^A(z) = (h_1^A(z), \dots, h_r^A(z))$ накладываются дополнительные ограничения.

Эталоны классов $\alpha_1 \leq \alpha_2 \leq \dots \leq \alpha_r$ разбивают числовую ось на $(r+1)$ промежутков, в каждом из которых могут использоваться не более двух локальных моделей кусочной аппроксимации. Показано, что функционал (5)

можно представить в виде: $I_2^n = \sum_{i=1}^r S_i(\alpha_{i-1}, \alpha_i, \alpha_{i+1})$. Последовательно строятся функции $F_r(\alpha_{r-1}, \alpha_r) = S_r(\alpha_{r-1}, \alpha_r, \alpha_{r+1})$,

$$F_i(\alpha_{i-1}, \alpha_i) = \min_{\alpha_{i+1}} [S_i(\alpha_{i-1}, \alpha_i, \alpha_{i+1}) + F_{i+1}(\alpha_i, \alpha_{i+1})], \quad i = (r-1), \dots, 1. \quad \text{Это}$$

выражение – рекуррентное уравнение Беллмана. Решая задачу минимизации $F_0(\alpha_0) = \min_{\alpha_1} [S_1(\alpha_0, \alpha_1, \alpha_2) + F_1(\alpha_0, \alpha_1)]$, получим оптимальное значение α_1 ,

по нему - значение α_2 и т.д. до получения оптимального значения α_r .

Литература

1. Бауман Е.В., Дорофеев А.А. Классификационный анализ данных // В сб.: “Избранные труды Международной конференции по проблемам управления. Том 1”. М.: СИНТЕГ, 1999.
2. Бауман Е.В., Дорофеев А.А., Чернявский А.Л. Методы структурной обработки эмпирических данных // Измерение, контроль, автоматизация. 1985, № 3.

Оценивание качества дискретной распознающей системы по обучающей выборке

В.Б. Бериков
(Новосибирск)

Введение

В данной работе продолжают исследования, изложенные в работах [1-4]. Под дискретной распознающей системой будем понимать такую систему, которая каждому из M различных входных состояний ставит в соответствие один из K распознаваемых классов. Пусть $\theta = (p_{1,1}, \dots, p_{l,j}, \dots, p_{K,M})$ – набор совместных вероятностей осуществления j -го состояния и l -го класса, $l=1, \dots, K$, $j=1, \dots, M$. Распознающая система «обучается» на случайной выборке наблюдений. Пусть N – объем выборки, $s = \{N_{l,j}\}$ – набор частот осуществления состояний для различных классов. Случайный вектор частот s подчиняется мультиномиальному распределению, и так как вектор θ неизвестен, можно рассмотреть семейство мультиномиальных моделей

распределения вектора частот с параметрическим множеством $\Theta = \{\theta\}$. Будем использовать байесовский подход, который основан на предположении о том, что параметр θ является случайной величиной с некоторым априорным распределением $p(\theta)$ при $\theta \in \Theta$.

В данной работе будет рассмотрен случай, когда θ подчиняется распределению Дирихле: $p(\theta) = \frac{1}{Z} \prod_{l,j} (p_{l,j})^{a_{l,j}-1}$, где $a_{l,j} > 0$ - некоторые известные параметры, Z - нормализующая константа. При $a_{l,j} \equiv 1$ получим случай равномерного распределения.

Рассмотрим вероятность ошибки P_{er} распознающей системы. Величину P_{er} , в случае фиксированной обучающей выборки, можно рассматривать как функцию, зависящую от случайного вектора θ . Пусть ν - частота ошибок на обучающей выборке.

Распределение вероятности ошибки

Теорема. Величина P_{er} подчиняется распределению с характеристической функцией $\varphi(t) = \Phi(\nu N + \tilde{A}, N + A; it)$, где

$\Phi(b, c; x) = \sum_{m=0}^{\infty} \frac{b_{(m)} x^m}{c_{(m)} m!}$ есть вырожденная гипергеометрическая функция,

через $b_{(m)}$ обозначено: $b_{(m)} = b \cdot \dots \cdot (b + m - 1)$, $b_{(0)} = 1$, i - мнимая

единица, $\tilde{A} = A - \sum_{j=1}^M a_{f(c_j), j}$, $A = \sum_{l,j} a_j^l$.

Следствие. Ожидаемая вероятность ошибки равна $EP_{er} = (\nu N + \tilde{A}) / (N + A)$.

С использованием данной теоремы, можно определить моменты более высокого порядка, доверительный интервал для вероятности ошибки, а также оценки объема выборки, достаточного для распознавания с заданными параметрами надежности [3]. Подчеркнем, что данные оценки получаются по обучающей выборке. Далее рассмотрим некоторые возможные практические применения полученных результатов.

Интервал для вероятности ошибки и критерий качества дерева решений

В известном алгоритме построения дерева решений для задачи распознавания [5] обучающая выборка делится на две части. Первая часть используется для построения «переобученного» дерева, а вторая служит для усечения (упрощения) данного дерева. Набор конечных вершин дерева можно рассматривать как пространство состояний распознающей системы.

В работе [6] для выбора оптимального варианта усечения предлагается Лапласовский критерий «минимальной ошибки» вида $Q=(\nu N+1)/(N+2)$, который, как можно увидеть, является частным случаем приведенной выше формулы для ожидаемой вероятности ошибки при $K=2$, $M=1$ и равномерном распределении вектора θ . Представляется перспективным использование для определения качества дерева не ожидаемую вероятность ошибки, но верхнюю границу доверительного интервала для этой вероятности.

Определение качества множественной распознающей системы

Под множественной распознающей системой будем понимать систему, проводящую классификацию в соответствии с набором нескольких решающих правил при помощи процедуры «голосования». Набор всевозможных сочетаний «голосов» отдельных правил будем рассматривать как множество состояний распознающей системы. При помощи приведенной выше теоремы, можно находить оценки ожидаемой вероятности ошибки и доверительного интервала для вероятности ошибки системы.

В качестве эксперимента, для базовых решающих правил распознавания автором данной работы были использованы деревья решений, формирующиеся на основе различных подсистем исходных признаков. Результаты решения различных прикладных задач, взятых из базы данных UCI Machine Learning Database Repository (<http://www.ics.uci.edu/~mlearn/MLRepository.html>) показали, что ожидаемая вероятность ошибки распознающей системы чаще всего несколько уменьшалась, в сравнении с отдельными решающими правилами. В дальнейшем интересно было бы исследовать алгоритм формирования деревьев на основе случайных подвыборок исходной выборки.

При финансовой поддержке РФФИ, грант № 01-01-00839.

Литература

1. Berikov, V.B. A priori estimates of recognition quality for discrete features. Pattern Recognition and Image Analysis, Vol. 12, N 3, 235-242. 2002.
2. Berikov, V.B. An approach to the evaluation of the performance of a discrete classifier. Pattern Recognition Letters. Vol. 23 (1-3), 227-233. 2002.
3. Berikov, V.B., Litvinenko A.G. The influence of prior knowledge on the expected performance of a classifier. Pattern Recognition Letters, 2003. (в печати)
4. Бериков В.Б. Априорные оценки качества распознавания при ограниченном объеме обучающей выборки. ЖВМиМФ, 2003, том 43, № 9, с.1448–1456 (в печати)
5. Breiman, L., Friedman, J., Olshen, R. and Stone, C. Classification and Regression Trees. Wadsworth International, California. 1984.
6. T. Niblett, I. Bratko. Learning decision rules in noisy domains. Expert Systems 86 Conf., Brighton, 15-18 Dec. 1986 In Developments in Expert Systems (ed. M. Bramer) Cambridge Univ. Press, 1986.

Об одной модели алгоритма классификации для задачи с K непересекающимися классами

А.Н. Блоконенков

(Москва)

Рассматривается задача классификации с K непересекающимися классами в M мерном признаковом пространстве с объемом обучающей выборки N . Каждый отдельный признак в этом пространстве может принимать значения как из конечного множества элементов (дискретный признак) так и из непрерывного (вещественный признак). Возможно использование признакового пространства в котором встречаются оба типа признаков. Допускается, что у части объектов обучения, а также у объектов которые будут предъявляться алгоритму для классификации, значения не всех признаков могут быть известны. В этом случае соответствующие компоненты вектора признаков у таких объектов помечаются специально зарезервированным для этой цели значением “-”.

Основной упор делается на получение модели алгоритма классификации, частота ошибки которого на обучающей выборке сходилась бы к вероятности ошибки на генеральной совокупности с ростом объема обучающей выборки N и числа используемых признаков M при соблюдении определенного соотношения между этими двумя параметрами. Особенностью предлагаемой модели является то, что в ходе ее обучения из всего множества признаков выбирается некоторое подмножество, и сам алгоритм (при рассмотрении его как решающей функции) зависит существенно только от тех входов (значений признаков предъявляемого объекта), которые попали в выбранное подмножество. На практике признаки могут вычисляться довольно сложными алгоритмами использующими некоторую априорную информацию о предметной области задачи или работающими в соответствии с принятой гипотезой о том, что рассматриваемая задача подчиняется некоторой модели. Примером последней может быть вероятностная модель, например гипотеза о том, что функция распределения вектора признаков при фиксированном классе принадлежит некоторому семейству функций распределения. В этом случае те алгоритмы, которые соответствуют признакам не вошедшим в выбранное подмножество, могут не вычисляться при работе алгоритма - что приведет к увеличению скорости распознавания, а те гипотезы о модели информационных связей в задаче, по которым были построены признаки не вошедшие в выбранное подмножество, могут рассматриваться как не соответствующие данным обучающей выборки и могут быть заменены на какие-то другие при дообучении алгоритма на новой выборке.

При построении алгоритма осуществляется переход от признакового описания объектов к их вероятностному описанию в разрезе классов и признаков. Для этого признаковому описанию $\langle x_1, \dots, x_M \rangle$ каждого

объекта x сопоставляется матрица $[dP_{kj}]_{k=1, j=1}^{K, M}(x)$, где ее элементы $dP_{kj}(x_j)$ - это либо значение в точке x_j функции плотности распределения признака j , восстановленной по объектам обучающей выборки принадлежащим классу k (случай непрерывного признака j); либо $dP_{kj}(x_j) = \frac{N_k(x_j)+1}{N_k+1}$ где N_k - число объектов в обучающей выборке из класса k у которых известно значение признака j , а $N_k(x_j)$ - число тех из них у которых значение признака j равно x_j (случай дискретного признака j). При восстановлении функции плотности распределения могут быть использованы имеющиеся априорные знания о ее виде, например тот факт, что она является монотонной или унимодальной. Если значение признака j известно не для всех объектов обучающей выборки класса k , то эти объекты не участвуют в восстановлении $dP_{kj}(x_j)$. Если не известно значение какой-либо компоненты признакового описания $\langle x_1, \dots, x_M \rangle$ объекта x , например $x_j = "-"$, то положим $dP_{kj}(x_j) = 1$ для всех k .

Алгоритм классификации строится как решающее правило следующего вида:

$$d(x) = \arg \max_{k=1..K} \ln[\Gamma_k (dP_{k1}(x_1))^{\Omega_1} (dP_{k2}(x_2))^{\Omega_2} \dots (dP_{kM}(x_M))^{\Omega_M}]$$

где $\Omega_j \in \{0, 1\}$, $j = 1..M$, $\Gamma_k \in R$, $\Gamma_k > 0$ при $k = 2..K$ и $\Gamma_1 = 1$.

Здесь $\langle \Omega; \Gamma \rangle = \langle \Omega_1, \dots, \Omega_M; \Gamma_2, \dots, \Gamma_K \rangle$ - это вектор параметров алгоритма, которые настраиваются по обучающей выборке, его двоичная компонента $\Omega = \langle \Omega_1, \dots, \Omega_M \rangle$ есть характеристический вектор, кодирующий подмножество тех признаков, которые будут использоваться при классификации. Алгоритм имеет следующую вероятностную интерпретацию: если выбранные в соответствии с Ω признаки были бы вероятно независимы, то величина $P_k(x) = \Gamma_k (dP_{k1})^{\Omega_1} (dP_{k2})^{\Omega_2} \dots (dP_{kM})^{\Omega_M}$ соответствовала бы апостериорной вероятности возникновения объекта класса k с признаковым

описанием x , тогда приведенное решающее правило принадлежало бы к классу байесовских. Компонента Γ соответствовала бы априорным вероятностям появления объектов соответствующих классов, отнормированным так чтобы $\Gamma_I = I$ (от этого решающее правило не меняется). Меняя Γ при фиксированных Ω , можно управлять вектором ошибок алгоритма $\langle E_1, \dots, E_K \rangle$, где $E_k = P\{d(x) \neq k \mid x \in K_k\}$ (соответствующая поверхность в пространстве $\langle E_1, \dots, E_K \rangle$ является основной характеристикой качества работы алгоритма классификации).

Для нахождения $\langle \Omega; \Gamma \rangle$ предлагается строить аналог минимаксного решающего правила. После того как будет найдена компонента Ω , варьированием Γ можно задавать требуемое соотношение между уровнем ошибки алгоритма на объектах разных классов. Для параметризованного указанным выше способом решающего правила $d_{\langle \Omega; \Gamma \rangle}$ определены связанные с ним значения эмпирической ошибки на каждом из классов:

$$e_k \langle \Omega; \Gamma \rangle = \frac{|\{i: d_{\langle \Omega; \Gamma \rangle}(x_i) \neq k, i \in \overline{1..N}, x_i \in K_k\}|}{|\{i: i \in \overline{1..N}, x_i \in K_k\}|}$$

где $[x_i]_{i=1}^N$ - объекты обучающей выборки.

Тогда набор параметров, оптимальный в смысле максимальной ошибки по классам, находится решением следующей оптимизационной задачи:

$$\langle \Omega; \Gamma \rangle^{\min \max} = \arg \min_{\langle \Omega; \Gamma \rangle} \max_{k=1..K} e_k \langle \Omega; \Gamma \rangle$$

Целевая функция в этой задаче принимает дискретный спектр значений, поэтому будут случаи вырождения, когда оптимальное значение целевой функции будет достигаться на разных наборах параметров $\langle \Omega; \Gamma \rangle$. Данное вырождение может быть снято следующим способом: по каждому признаку j в отдельности может быть построен классифицирующий алгоритм из класса байесовских решающих правил, описываемый набором параметров $\Gamma_j = \langle \Gamma_{2j}, \dots, \Gamma_{Kj} \rangle$:

$$d_j \langle \Gamma_j \rangle (x) = \arg \max_{k=1..K} \Gamma_{kj} dP_{kj}(x_j) \quad \text{где } \Gamma_{Ij} = I$$

Соответственно могут быть определены связанные с ним значения эмпирической ошибки на каждом из K классов:

$$e_{kj} \langle \Gamma_j \rangle = \frac{| \{ i: d_{j \langle \Gamma_j \rangle}((x_i)_j) \neq k, i \in \overline{1..N}, x_i \in K_k \} |}{| \{ i: i \in \overline{1..N}, x_i \in K_k \} |}$$

затем среди класса байесовских правил по j признаку можно найти параметры Γ_j минимаксного решающего правила и найти его ошибку:

$$e_j^{\min \max} = \min_{\langle \Gamma_j \rangle} \max_{k=1..K} e_{kj} \langle \Gamma_j \rangle$$

Обозначим $p_j = 1 - e_j^{\min \max}$, тогда добавлением величины $P \langle \Omega_1, \dots, \Omega_M \rangle = (p_1)^{\Omega_1} (p_2)^{\Omega_2} \dots (p_M)^{\Omega_M}$ в целевую функцию снимается вырождение в упомянутой выше оптимизационной задаче:

$$\langle \Omega; \Gamma \rangle^{\min \max} = \arg \min_{\langle \Omega; \Gamma \rangle} \max_{k=1..K} C \cdot e_k \langle \Omega; \Gamma \rangle - P \langle \Gamma \rangle$$

где константа $C > 0$ берется достаточно большой, чтобы оптимальное решение данной задачи не выходило из множества оптимальных решений исходной. Одним из свойств предложенного способа снятия вырождения является то, что среди множества оптимальных решений исходной задачи будет выбрано решение с минимальным по включению подмножеством признаков, описываемым компонентой решения $\overline{\Omega}$. Логарифмированием встречающихся произведений полученная невырожденная оптимизационная задача сводится к задаче смешанного целочисленного программирования [3,7,9,10], в которой $M + N$ оптимизируемых переменных – булевы, K переменных – вещественные. Матрица линейных ограничений в полученной задаче ЦЛП состоит из $N(K - 1) + K + 1$ строк и содержит вещественные элементы.

Обозначим $e^{\min \max} = \max_{k=1..K} e_k \langle \Omega, \Gamma \rangle^{\min \max}$ величину получаемого оптимума в исходной задаче. Обозначим $e = \frac{| \{ i: d \langle \Omega, \Gamma \rangle^{\min \max} (x_i) \neq k_i, i \in \overline{1..N}, x_i \in K_{k_i} \} |}{N}$ частоту ошибки найденного оптимального алгоритма на объектах обучающей выборки, тогда $e \leq e^{\min \max}$. Обозначим $E = P \{ d \langle \Omega, \Gamma \rangle^{\min \max} (x) \neq k, x \in K_k \}$ вероятность ошибки найденного алгоритма на генеральной совокупности.

Для вероятностного обоснования экстраполяционных свойств предложенной модели построения алгоритма классификации используется

результат из [6], полученный для случая задачи с двумя классами при условии что обучающая выборка является простой в вероятностном смысле. С учетом введенных выше обозначений он формулируется так:

$$P \left\{ E \leq e + \sqrt{6 \frac{\ln \Delta_A([x_i]_{i=1}^N)}{N}} + 5 \sqrt{\frac{\ln(2/\eta)}{N}} \right\} \geq 1 - \eta$$

где $\Delta_A([x_i]_{i=1}^N)$ - это число способов, которыми можно расклассифицировать на два класса выборку, на которой производится обучение путем варьирования параметров алгоритма d ($\langle \Omega, \Gamma \rangle$ - параметры алгоритма в данном случае).

Так как $e \leq e^{\min \max}$ и так как в случае применения описанной модели к задаче с двумя классами $\Delta_A([x_i]_{i=1}^N) \leq N 2^M$, а также если M и N растут так что $M \leq cN - \ln N$ для некоторой константы $c > 0$, и если совокупная информативность признаков растет (то есть $e^{\min \max} \rightarrow 0$), то из приведенного неравенства следует, что вероятность ошибки E построенного алгоритма при работе на генеральной совокупности сходится к нулю по вероятности с ростом M и N .

Литература

1. Воронцов К.В. Локальные базисы в алгебраическом подходе к проблеме распознавания //Диссертация на соискание степени кфмн. Москва 1999.
2. Журавлев Ю.И. Избранные научные труды. //Магистр. Москва, 1998.
3. Кузюрин Н.Н. Вероятностные приближенные алгоритмы в дискретной оптимизации. //Дискретный анализ и исследование операций. Москва, 2002. С.2, Т.9, С. 97-114.
4. Рудаков К.В. Алгебраическая теория универсальных и локальных ограничений для алгоритмов распознавания //Диссертация на соискание степени дфмн.
5. Vapnik V. The nature of Statistical Learning Theory. //Springer-Verlag. New York, 1995.
6. Boucheron S., Lugosi G., Massart P. A sharp concentration inequality with applications. //CNRS - Universite Paris-Sud. Orsay-Cedex, 1999.
7. Minoux M. Mathematical programming: Theory and algorithms. //Bordas. Paris, 1989.
8. Sill J. The capacity of monotonic functions. //Elsevier science. Berkeley, 1997.
9. Aardal K., Weismantel R., Wolsey L. //Non-standard approaches to integer programming. //DONET. 2000.

10. Mitchell J. Branch-and-cut algorithms for combinatorial optimization problems. //Mathematical sciences. NY, 1999.

Распознавание образов при заданных ограничениях

Ю.А. Бродская

(Саратов)

Несмотря на существенные результаты, полученные в математической теории распознавания в последние десятилетия, нельзя не признать успехи в некоторых приложениях этой теории весьма скромными. Одна из причин этого – недостаточное внимание математиков к особенностям предметных областей. Эти особенности зачастую могут быть выражены в виде ограничений на распознавание. В первую очередь, при выборе признаков распознавания (диагностики, идентификации). К ограничениям на распознавание в приложениях следует отнести, в первую очередь, финансово-экономические, временные, биологические, технические, погодно-климатологические, технологические, юридические, а также парные отношения ограничений для разных признаков. Финансово-экономические ограничения (на затраты ресурсов) рассматриваются в ряде работ, например, [1,2]. Обычно оптимальные решения принимаются с учетом одного ограничения. К предметным областям, где финансово-экономические, временные и биологические ограничения оказывают существенное влияние на качество распознавания, следует отнести, в первую очередь, медицину, микробиологию, ветеринарию, криминалистику. Эти предметные области отличаются большой интенсивностью потока требований на распознавание и резкими колебаниями этой интенсивности, особенно в экстремальных ситуациях, возникающих во время военных конфликтов, эпидемий, при увеличении активности криминальных элементов. К особенностям распознавания в этих предметных областях следует отнести то, что ресурсные и временные ограничения в значительной степени определяются ситуациями распознавания и субъективными представлениями о них лица, принимающего решение (ЛПР). Поэтому первоочередными задачами, выполняемыми на стадии ОРО, становятся задачи подготовки для ЛПР справочных данных и средств обработки данных. К справочным данным относятся списки: 1) моделей ситуаций распознавания, 2) норм затрат ресурсов и времени при измерении значений признаков $x_i \in X$ ($i=1, \dots, n$; $n=|X|$); X – множество признаков, описывающих объекты, 3) пар признаков, принадлежащих к различным видам бинарных отношений групп признаков, 4) обязательных и/или недопустимых сочетаний работ по измерению значений признаков в заданной предметной области. Список моделей ситуаций – есть таблица, в строках которой даны модели ситуаций. В строке таблицы содержатся: а) затраты ресурсов при измерении значений всех

признаков $x_i \in Q_s$; $Q_s \in X$; $s \in S$ (S – множество строк таблицы); б) затраты времени при измерении значений всех признаков $x_i \in Q_s$; в) значение относительной точности распознавания ω_{Q_s} ; г) список признаков $x_i \in Q_s$; д) сетевой график работ по измерению значений признаков. Таблица моделей ситуаций описывает точки пространства ситуаций, оптимальных по Парето [3].

Под относительной точностью распознавания ω_{Q_s} здесь понимается доля контрольных объектов, правильно распознанных с помощью множества признаков $Q_s \subseteq X$ среди контрольных объектов, правильно распознанных с помощью множества признаков X : $\omega_{Q_s} = \gamma_{Q_s} / \gamma_X$. Список норм затрат ресурсов и норм затрат времени содержит для каждого признака $x_i \in X$ одно или несколько значений норм затрат ресурсов (общих и/или по видам ресурсов) и норм времени (максимальных, минимальных). Или (при отсутствии таковых) числовые отношения норм затрат к минимальной норме затрат. В списке пар признаков для каждой пары фиксируются бинарные временные отношения между работами по измерению значений признаков. Приняты три вида временных отношений в паре: два вида (из трех) соответствуют парам работ, измерения значений которых выполняются в непересекающиеся периоды времени. Первый вид отношений $\sigma_1 \subset B \times B$ соответствует заданному порядку работ, второй вид: $\sigma_2 \subset B \times B$ - любому порядку работ, третий вид - $\sigma_3 \subset B \times B$ - работам, пересекающимся во времени по умолчанию. В качестве подмножества признаков $Q_s \subseteq X$ используются: а) тест с минимальными затратами ресурсов и/или времени; б) подмножеств теста, оптимальное по затратам и относительной точности распознавания. В результате исследований выявлено, что тест с минимальными затратами ресурсов – есть тупиковый тест. Тест с минимальными затратами времени, в общем случае, не является тупиковым.

Тесты с минимальными затратами и/или времени формируются на репрезентативной обучающей выборке. Обучающая выборка является репрезентативной относительно тестов с минимальными затратами и их подмножеств, если выполняется условие: $\omega_{T_{\min}} \geq \omega_1$, (1) где: $\omega_{T_{\min}}$ - относительная точность распознавания объектов контрольной выборки с помощью минимального теста, сформированного на обучающей выборке; ω_1 - заданное пороговое значение относительной точности распознавания.

Если условие (1) не выполняется, то обучающая выборка пополняется эталонными объектами или абстрактными объектами, сформированными с помощью датчика псевдослучайных чисел с учетом «запретов», формулируемых экспертом предметной области (например, в микробиологии – [4]). Пополнение обучающей выборки выполняется, в общем случае, в нескольких итерациях. Для формирования минимальных тестов и тестов с минимальными затратами разработан усовершенствованный вариант метода «наискорейшего спуска» [5]. Выбор столбца, принадлежащего тесту, определяется информативностью признака (соответствующего столбцу), которая принята пропорциональной количеству строк матрицы различий, покрываемых столбцом и обратно пропорциональной затратам ресурсов (времени) и значению критерия, характеризующему зависимость признака (столбца) от всех остальных.

Разработаны методы формирования подмножеств тестов для распознавания. Формирование теста с минимальными затратами времени (минимальной общей продолжительностью работ) выполняется на основе разработанного метода автоматизированного формирования сетевого графика работ (СГР) по измерению значений признаков. Формирование теста с оптимальным соотношением затрат ресурсов, затрат времени и относительной точности распознавания выполняется в следующем порядке: формируется тест с минимальными затратами времени; из этого теста исключаются признаки, избыточные для тупикового теста. Полученный тупиковый тест есть тест с минимальными затратами ресурсов и времени. Ведутся опытные испытания методов распознавания и прогнозирования с учетом ограничений в медицине [6].

Литература

1. Загоруйко Н.Г. Методы распознавания и их применение. – М.: Советское радио, 1972. – 208 с.
2. Горелик А.Л., Скрипкин В.А. Методы распознавания. – 3 изд. – М.: Высш. Школа, 1989. – 232 с.
3. Розен В.В. Цель – оптимальность – решение (Математические модели принятия оптимальных решений). – М.: Радио и связь, 1982. – 168 с., ил (кибернетика).
4. Заварзин Г.А. Фенотипическая систематика бактерий. Пространство логических возможностей. – М.: Наука, 1974. – 142 с.
5. Чегис И.А., Яблонский С.В. Логические способы контроля электрических схем. Труды математического института им. В.А. Стеклова, 1958, т. 51 – С.270-360.
6. Бродская Ю.А., Маринушкин Д.Н., Нечаев В.Н., Тугушева В.Н., Балабанов Н.Г., Василенко А.П. Теоретические предпосылки использования теории распознавания образов в прогнозировании преждевременного прерывания беременности.// Искусственное

прерывание беременности. – М.: Научный центр акушерства, гинекологии и перинатологии РАМН, СГМУ, 2001. – С.33-35.

Конструктивная компьютеризация булевой алгебры

Н.П. Брусенцов, Ю.С. Владимирова

(Москва)

Конструктами называются высокоуровневые типы данных, конструируемые в диалоговой системе структурированного программирования ДССП [1]. Конструкт – это процедурно интерпретируемый формат, как правило, битный вектор параметрически задаваемой длины с набором процедур, реализующих базисные операции над его значениями. Например, конструкт "Комплексное число" – двухкомпонентный числовой вектор с определенными над ним арифметическими операциями.

Особый интерес представляют неарифметические конструкты, в частности, интерпретирующие тот же вектор битов как представленное в той или иной форме выражение булевой алгебры. Они открывают возможность программируемого преобразования выражений, выявления отношений, которыми взаимосвязаны выражения, решения логических уравнений, в чем Дж.Буль небезосновательно усматривал "наиболее общую проблему логики" [2].

Будем интерпретировать n -битный вектор как упорядоченный перечень терминов x, y, z, \dots, w . Другими словами, сопоставим данные термины битам вектора как значения индекса: x -бит, y -бит, ..., w -бит. Такой вектор естественно кодирует четко определенные совокупности терминов: если термин принадлежит отображаемой совокупности, то обозначенный им бит вектора принимает значение 1, а если не принадлежит, то 0. Так в случае четырехбитного вектора $xuzw$ совокупность терминов x и z отображается значением 1010, а пустая совокупность 0000.

Имеется два типа совокупностей: *конъюнктивные* (множества) и *дизъюнктивные* (классы). Им соответствуют две интерпретации вектора битов, два конструкта – *К-шкала* и *Д-шкала*. Эти шкалы кодируют значениями n -битного вектора (трактуемыми обычно как двоичные числа) n -арные элементарные конъюнкцию и дизъюнкцию, называемые далее *индивидуальной конъюнкцией* и *предполной дизъюнкцией*. Над шкалами, поскольку они отображают совокупности, определены теоретико-множественные операции инверсии, пересечения и объединения, реализованные на компьютерах как побитные отрицание, конъюнкция и дизъюнкция. Термины, содержащиеся в индивидуальной конъюнкции (предполной дизъюнкции) неотрицаемыми, необходимо *принадлежат* сопоставленной ей совокупности и *присущи* охарактеризованной конъюнкцией вещи, а в случае дизъюнкции *причастны* представляемому ею

классу. Сопоставленные этим терминам биты шкалы принимают значение 1. Отрицательные термины не принадлежат совокупности, не присущи, не причастны, и их биты в шкалах принимают значение 0.

Произвольная n -арная булева функция выразима в совершенных нормальных формах – дизъюнктивной (СДНФ) и конъюнктивной (СКНФ). Первая означает дизъюнктивную совокупность индивидуальных конъюнкций, вторая – конъюнктивную совокупность предполных дизъюнкций. Каждая из них отобразима посредством 2^n -битного вектора, подобно тому, как n -битным вектором отображаются совокупности терминов. Возникают еще два типа конструкций: *ДК-шкала* для кодирования СДНФ и *КД-шкала* для СКНФ. Биты этих шкал индексируются значениями соответственно К-шкал и Д-шкал. Над ДК- и КД-шкалами также определены операции инверсии, пересечения и объединения, причем инверсия равнозначна булеву отрицанию отображенного шкалой выражения, пересечение – конъюнкции, объединение – дизъюнкции однотипных СНФ-выражений [3]. Таким образом булева алгебра совершенных нормальных форм сводится к уже компьютеризованной алгебре ДК- и КД-шкал.

Компьютеризация несовершенных нормальных форм достигается введением конструкций К- и Д-шкалы тритов, позволяющих кодировать нечеткие совокупности (неиндивидуальные конъюнкции, непредполные дизъюнкции) [4]. Введение же тритных ДК- и КД-шкал представляет собой существенное обобщение булевой алгебры, придающее ей диалектический, адекватный реальности характер [5].

Литература

1. Концептуальная характеристика РИИИС-процессора / Н.П.Брусенцов, С.П.Маслов, Х.Рамиль Альварес, С.А.Сидоров // Интегрированная система обучения, конструирования программ и разработки дидактических материалов. – М.: Изд-во ф-та ВМиК МГУ, 1996. С. 16-43.
2. Брусенцов Н.П., Владимирова Ю.С. Решение булевых уравнений // Методы математического моделирования. – М.: Диалог-МГУ, 1998 г. С. 59-68.
3. Владимирова Ю.С. Конструктивная реализация булевой алгебры // Интегрированная система обучения, конструирования программ и разработки дидактических материалов. – М.: Изд-во ф-та ВМиК МГУ, 1996. С. 16-43.
4. Брусенцов Н.П., Владимирова Ю.С. Троичная компьютеризация булевой алгебры // Цифровая обработка информации и управление в чрезвычайных ситуациях. – Минск: Институт технической кибернетики НАНБ, 2002. Т. 2. С. 195-199.
5. Брусенцов Н.П. Интеллект и диалектическая триада // Искусственный интеллект, 2'2002. – Донецк, 2002. С. 53-57.

О субквадратичных алгоритмах синтеза плоских представлений конечных метрических конфигураций.

А.С. Вальков

(Москва)

Проблема синтеза плоских представлений метрических конфигураций, известная с конца прошлого века, важна для визуализации и анализа данных. Имеются методы, имеющие квадратичную (по количеству объектов) сложность. Проблема достаточно хорошо изучена для конфигураций малого объема (порядка 100-1000 объектов). Однако, на практике нередко конфигурации, насчитывающие сотни тысяч объектов. Поэтому разработка алгоритмов, имеющих менее чем квадратичную сложность, а также поиск классов задач, разрешимых с такой сложностью актуальны.

Метрической конфигурацией будем называть набор объектов с введенной на них метрикой (вообще говоря, неевклидовой).

Задача синтеза плоских представлений метрических конфигураций состоит в сопоставлении объектам точек на координатной плоскости таким образом, чтобы евклидовы расстояния между точками на плоскости в том или ином смысле мало отличались от заданных исходной метрикой расстояний между соответствующими объектами.

В докладе обсуждаются различные классы таких задач и подходы к построению для них быстрых (субквадратичных) алгоритмов.

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (проект № 02-01-00326).

Комбинированные индуктивные методы в редукционных алгоритмах

В.И. Васильев

(Киев)

Все индуктивные методы, основанные на неполной индукции, отличаются тем, что в них общие выводы делаются на основании частных фактов, а это может привести как к верным, так и к ошибочным решениям. Поэтому качество индуктивного вывода должно определяться не только и не столько объяснением отдельных, полученных в процессе экспериментов фактов, сколько экстраполяционными способностями этих выводов, их способностью к экспансии в область явления, не охваченную экспериментами. При этом всякий раз, когда модель процесса выбирается из слишком сложного класса, всё в большей мере не хватает эмпирических данных для её однозначного объяснения, т.е. модель оказывается сложнее того, что несут в себе накопленные факты, и эти факты просто не в состоянии воссоздать такую модель. Чрезмерное усложнение без учета объема экспериментальных данных приводит к непомерной свободе

поведения аппроксимирующей функции в области, не охваченной экспериментом, в то время как более простые модели в этой области ведут себя более «осторожно». Это происходит потому, что при ограниченном объеме выборки качество восстанавливаемой функции зависит не только от качества аппроксимации в точках эксперимента, но еще и от сложности аппроксимирующей функции, и от размерности пространства, в котором эта функция восстанавливается. Эта особенность заставляет сосредоточить внимание на правильном соотношении сложности приближающей функции с объемом обучающей выборки, что привело к созданию редуцированных (упрощающих) алгоритмов.

Среди немногих методов, в которых особое внимание уделяется поиску такого соотношения, можно отметить метод группового учета аргументов (МГУА) [1] и метод предельных упрощений (МПУ) [2]. Поэтому в докладе рассматриваются эти два метода с точки зрения возможностей их взаимодополнения.

В методе МГУА задача решается в несколько этапов. Вначале из всех независимых переменных (аргументов) образуются группы и относительно каждой группы составляется простое частное описание. Параметры этого описания определяются по обучающей выборке. Качество каждой такой частной модели проверяется на проверочной выборке, не участвующей в процессе обучения. Проверочная выборка играет роль «сита», отсеивающего все чрезмерно сложные модели, не имеющие права на существование в рамках ограниченной информации. Прошедшие самоотбор простые модели, ведущие себя «осторожно» на новых данных проверочной выборки, допускаются к усложнению модели следующего ряда. В результате получается множество решений, из которых выбирается наилучшее в смысле экстраполяционных свойств.

В методе предельных упрощений (МПУ) расширение пространства ограничено дедуктивным, основанном на теореме отбором. Дедуктивное ограничение как бы взвешивает каждое усложнение и определяет чего оно стоит. Осуществляется последовательный синтез пространства, в котором возможно линейное разделение. Для этой цели используется альфа-процедура [2]. Для дальнейшего усложнения решающего правила можно использовать промежуточные переменные, получаемые в МГУА. В случае, когда линейная модель, полученная при помощи МПУ, не приводит к полному решению задачи, можно использовать промежуточные переменные, получаемые на различных этапах в МГУА. Эти переменные уже прошли дополнительную проверку на проверочной выборке, а поэтому обладают удовлетворительными экстраполяционными свойствами. В результате каждая переменная, подаваемая на вход альфа-процедуры пройдет двойную проверку: по способности работать на новых данных и по способности взять на себя нагрузку, определяемую условиями теории. Такая двойная проверка

позволяет выбирать только те признаки, которые, во-первых, сильнее всего улучшают окончательное решение, а во-вторых, не вносят чрезмерных усложнений, ухудшающих работу результирующей модели на новых данных. В этом случае МГУА играет роль отбора нелинейных переменных для альфа-процедуры. Линейные переменные отбираются обычным алгоритмом альфа-процедуры, а если среди них не найдется достаточного количества переменных, то начинает работать МГУА, постепенно усложняя модель.

Алгоритмы, основанные на МГУА и МПУ могут генерировать множества почти равноценных по качеству, но существенно различных по структуре, решающих правил. На базе этих решающих правил могут быть организованы коллективы, принимающие решения, к которым можно применить все те методы, которые разработаны в теории принятия коллективных решений. В этом случае указывается только ранг формируемого коллектива, после чего происходит самоорганизация коллектива заранее указанного ранга. Заранее никто не указывает, какой структуры решающие правила должны входить в коллектив, алгоритм сам выбирает эти правила и сам формирует их структуру. Конструктор должен указать только ранг формируемого коллектива.

Усложнение решающего правила, конструируемого при помощи альфа-процедуры можно приводить используя аналог алгоритмов вычисления оценок. Для этого зафиксируем какой-либо объект обучающей выборки и назовем его опорным. Выбрав некоторую комбинацию свойств, зафиксируем её на опорном объекте. Все остальные объекты будут отличаться от опорного объекта. Если в качестве меры сравнения взять расстояние в пространстве выбранных свойств, то все объекты будут удалены от опорного объекта на некоторое расстояние. Проранжировав все объекты обучающей выборки по мере удаления их от опорного, получим одномерную, непрерывную шкалу расстояний, на которой все объекты будут расположены по мере удаления от опорного объекта. Такая шкала может рассматриваться как сложное производное свойство всех объектов, которое легко использовать самостоятельно на входе альфа-процедуры. В результате альфа-процедура из огромного множества производных свойств выберет только те, которые будут максимально способствовать линейному разделению образов.

Литература

1. Ивахненко А.Г. Долгосрочное прогнозирование и управление сложными системами. – Киев; Техника, 1975 – 311с.
2. Васильев В.И. Теория редукции в проблемах экстраполяции // Проблемы управления и информатики. – 1996. - №1,2 – с.239-281.

Ортогональные скелетоны в задаче оптимизации вычислительной сложности алгоритма ДАРБИ

Ю.Г. Васин, Л.И. Лебедев

(Нижний Новгород)

Введение

До настоящего времени в отечественной и зарубежной литературе системам распознавания текстов уделяется большое внимание. Объясняется это потребностью автоматического ввода различного рода документов. В [1] описана технология ввода текстовых документов произвольного формата на базе алгоритма ДАРБИ. В результате эксплуатации ДАРБИ возникла потребность модернизации ее в плане увеличения быстродействия. Осуществить это предлагается на основе использования ортогональных скелетонов.

Постановка задачи.

В системе распознавания ДАРБИ используются два алгоритма распознавания, базирующихся на векторном (контурном) представлении информации (контурное распознавание) и растровом описании входных данных (растровое распознавание). Контурное распознавание базируется на корреляционно-экстремальных методах определения сходства плоских форм и является инвариантным относительно ортогональных преобразований и масштабирования. Это быстродействующий метод, вычислительная сложность которого пропорциональна числу узловых точек в описаниях объекта и эталона. Растровое распознавание также основано на вычислении

оценки сходства, но с использованием метрики L^1 . Выбор именно этого алгоритма здесь обусловлен тем, что он обладает высокой помехозащищенностью и приемлемым качеством распознавания. Растровое распознавание отвечает в основном за распознавание пропущенных символов и формирование начала и конца распознаваемой последовательности. Инвариантности оценки сходства при растровом распознавании относительно ортогональных преобразований, масштабирования и типа шрифта не требуется, так как эти параметры определяются по результатам контурного распознавания. Поэтому вычисление оценки сходства осуществляется в локальной области, размеры которой больше области задания эталона на несколько единиц растра. Тем не менее, тестирование показало, что несмотря на полученные упрощения в вычислении оценок сходства в растровом распознавании, на него приходится в среднем 85-90% всего времени распознавания последовательности символов. Поэтому, задача состояла в оптимизации вычислительной сложности растрового распознавания. Анализ показал, что для выбранного алгоритма растрового распознавания это возможно в основном за счет уменьшения числа предъявляемых эталонов.

Методы решения

Уменьшение числа предъявляемых эталонов возможно только по результатам предварительной классификации. Особо отметим, что классификация должна осуществляться в автоматическом режиме на базе используемых эталонов. Очевидно, что методы и алгоритмы предварительной классификации должны быть очень быстродействующими и, следовательно, опираться на более упрощенное описание, чем входное растровое представление информации, построение которого также должно осуществляться быстродействующими алгоритмами. Такими качествами обладают ортогональные скелетоны $Sc \rightarrow X$ и $Sc \rightarrow Y$ [2]. Описание скелетонов представляется в виде набора линий. Под линией здесь понимается множество примыкающих друг к другу точек скелетона на растре.

Рассмотрим два алгоритма предварительной классификации на основе использования векторных описаний ортогональных скелетонов.

Алгоритм А. *Алгоритм предварительной классификации на основе вычисления оценок сходства.*

Этот алгоритм реализует следующую схему вычислений. По размеру текущего эталона из распознаваемого фрагмента выделяется область и отбирается множество линий описания одного из ортогональных скелетонов фрагмента, которые принадлежат этой области. Далее вычисляется центральная точка и относительно ее производится центрирование описаний отобранных линий. Для устойчивости к шумам случайной природы центральная точка вычисляется как среднее всех точек линий области, взятых с весами, которые пропорциональны расстояниям от точки скелетона до границы объекта. Далее происходит сопоставление центрированных описаний скелетонов эталона и объекта. Сходство эталона и объекта считается неудовлетворительным, если хотя бы в ε - окрестности одной линии эталона число точек из описания скелетона объекта будет в процентном отношении меньше заданного порога. Если сходство с данным эталоном признано неудовлетворительным, он не включается в группу, на основе которой будет осуществляться растровое распознавание. Для устойчивости работы алгоритма при установлении сходства рассматриваются только линии эталона с числом точек, превышающим порог, который определяется исходя из размеров эталонов.

Алгоритм Б. *Структурный алгоритм предварительной классификации.*

Этот алгоритм предусматривает следующую последовательность операций. Вначале все линии скелетона разбиваются на две группы: прямые линии и кривые. На основе прямых линий строится составное описание линий по правилу: несколько прямых линий объединяются в одну, если они геометрически лежат на одной прямой. Это осуществляется в целях устойчивости структурного описания скелетонов при рассыпании контуров

объектов. Далее, все составные прямые линии по отношению к линии наклона шрифта подразделяются на базовые и вспомогательные. При совпадении углов наклона составная прямая линия относится к базовым, в противном случае к вспомогательным. В результате структурное описание объектов и эталонов задается тройкой $(N_{\sigma}, N_{\sigma}, N_{\kappa})$ - количеством базовых и вспомогательных прямых линий и количеством кривых. При совпадении троек эталон включается в группу, на базе которой будет проведено растровое распознавание. Отметим, что ограничения на предмет использования линий скелетона при формировании структурного описания являются такими же, что и для *Алгоритма А*.

Полученные результаты

Исследования проводились на текстах, написанных на кириллице с использованием различных шрифтов. Оказалось, что предварительную классификацию целесообразно вести только с использованием скелетона $S_c \rightarrow X$. Статистические оценки предлагаемых алгоритмов предварительной классификации таковы. Вероятность правильной классификации равна соответственно 0.8 и 0.9. С учетом вероятностей появления букв в тексте в среднем при правильной классификации группу составят 1.0974 и 1.7172 эталона соответственно. Таким образом, среднее число эталонов, на базе которых осуществляется растровое распознавание, составит 7.2584 и 4.6738 соответственно. Однако, среднее время на распознавание уменьшается приблизительно только в 2 и 4 раза соответственно, так как в приведенных расчетах не учитывалось время на формирование растрового фрагмента, построение скелетона и работы алгоритмов предварительной классификации.

Заключение

Для текстов, использующих символы кириллицы, предпочтительным является применение *Алгоритма Б*. Использование этого алгоритма для модификации ДАРБИ позволяет решить поставленную задачу. В тоже время очевидно, что, например, для текстов с символами арабской письменности более эффективным будет использование *Алгоритма А* (из-за больших отличий в мощностях классов, формируемых на принципах *Алгоритма Б*).

Работа выполнена при поддержке РФФИ (проект 00-15-96108) и ФЦП «Интеграция» (проект К0392).

Литература

1. Васин Ю.Г., Лебедев Л.И., Плесков А.В., Игнатъева В.П. Технология автоматического ввода текстовых документов произвольного формата на основе двухуровневого метода распознавания. // Математические методы распознавания образов (ММРО-9): 9-ая Всероссийская. конф.: Тез. докл. / М.: Изд-во «АЛЕВ-В», 1999. С.149-151.
2. Васин Ю.Г., Лебедев Л.И., Морозов В.А. Модификация двухуровневого

алгоритма распознавания последовательностей графических изображений. //Математические методы распознавания образов (ММРО-10): 10-ая Всеросс. конф.: Тез. докл. / М.: Изд-во «АЛЕВ-В», 2001. С.176-179.

Об одном способе регуляризации некорректно поставленных задач распознавания образов.

Д.П. Ветров
(Москва)

Введение

На сегодняшний день, подавляющее большинство алгоритмов распознавания образов являются представителями параметрических семейств. При этом алгоритм $A(\alpha)$ ищется в соответствующем семействе алгоритмов $A = \{A(\alpha) \mid \alpha \in D\}$. Совокупность параметров α однозначно определяет алгоритм. Искомый алгоритм можно представить следующим образом: $A^*(\alpha) = \arg \max_{A \in A} \Phi(A)$. В качестве функционала $\Phi(A)$ обычно

используется число правильно распознанных объектов обучающей или контрольной выборки. Заметим, что такая постановка задачи приводит к неоднозначностям (особенно на малых выборках) в силу того, что функционал качества принимает только целочисленные значения. Так как параметры α обычно являются непрерывными величинами, то это приводит к тому, что максимум функционала качества достигается, вообще говоря, на континууме различных алгоритмов из семейства A . Кроме того, такой функционал качества не учитывает возможности перенастройки алгоритмов, для предотвращения которой приходится применять независимые процедуры контроля и, таким образом, решать многокритериальную задачу оптимизации. Следовательно, классическая задача распознавания является некорректно поставленной. Заметим, что хотя в качестве искомого алгоритма всегда можно взять решение соответствующей оптимизационной задачи, оно может оказаться неустойчивым и почти наверняка неединственным. Для решения некорректно поставленных задач в математике используются различные методы регуляризации (т.е. сведения исходной задачи к корректной) [1].

В настоящей работе предлагается способ регуляризации функционала качества, который бы обеспечил корректную постановку и решение задачи распознавания.

Построение регуляризатора

Рассмотрим гипотетический «идеальный» классификатор

$K : R^n \rightarrow \{1, \dots, l\}$, ставящий каждому объекту в соответствие его истинный класс. Про него известны лишь его значения в точках контрольной выборки $\{S_1, \dots, S_q\}$. Введем в n -мерном пространстве признаков следующую меру μ :

$$\forall X \subset R^n \quad \mu(X) \stackrel{df}{=} |\{S_i \mid S_i \in X\}|$$

Тогда классическую задачу распознавания можно переписать следующим образом:

$$A^*(\alpha) = \arg \min_{A \in \mathcal{A}} \mu(Y) \quad (1)$$

где $Y = \{S_i \mid A(S_i) \neq K(S_i)\}$. Как было сказано выше, такая задача всегда имеет решение.

Допустим теперь, что классовая принадлежность объектов известна точно, а значения их признаков – с некоторой погрешностью δ . Такая ситуация часто возникает при решении прикладных задач в которых классы являются объективными характеристиками объектов, а признаки – округленными результатами измерений некоторых показателей. Определим множество X_δ следующим образом:

$$X_\delta = \{S_i \mid A(S_i) = K(S_i), \exists S \in R^n : \rho(S, S_i) < \delta, A(S) \neq A(S_i)\}$$

Другими словами, в множество X_δ попадают правильно классифицированные объекты, в δ -окрестности которых, алгоритм A меняет ответ. Будем говорить, что на таких объектах алгоритм неустойчив. Очевидно, что практическая ценность от их правильной классификации невелика. Пусть

$$\Phi(A) = -(\mu(Y) + \theta \mu(X_\delta)) \quad (2)$$

Тогда при θ близких к единице максимизация такого функционала будет обеспечивать получение устойчивого, насколько это возможно, решения. Заметим, однако, что при использовании функционала качества (2) единственность решения по-прежнему не обеспечивается, так как мера $\mu(\cdot)$ принимает целые значения.

Пусть $d_j = \arg \max_r \{S \mid \rho(S, S_j) < r, A(S) = A(S_j)\}$, т.е. радиус максимальной окрестности объекта, в которой алгоритм A не меняет своего ответа. Не ограничивая общности, предположим, что $d_1 \geq d_2 \geq \dots \geq d_q$. Введем в рассмотрение следующий регуляризатор:

$$R_\delta(A) = -(\mu(Y) + \theta\mu(X_\delta)) + \beta_1 d_1 + \dots + \beta_q d_q \quad (3)$$

Определение. Задача распознавания называется корректно поставленной в широком смысле, если

- 1) ее решение всегда существует
- 2) решение почти всегда единственно, т.е. вероятность того, что оно не единственно равна нулю
- 3) объекты, на которых решение неустойчиво считаются неправильно распознанными.

Теорема 1. Задача распознавания образов с функционалом качества (3) является корректно поставленной в широком смысле при $\theta = 1$ и следующей асимптотике:

$$0 < \beta_1 < \frac{1}{qR}, 0 < \beta_2 < \frac{d_1}{q}, \dots, 0 < \beta_q < \frac{d_2}{q}$$

где $R = \min_{i \neq j} \rho(S_i, S_j)$.

Заметим, что функционал, определяемый формулой (3) существенно зависит от параметра регуляризации δ . При больших δ алгоритм становится менее «эластичным» и, следовательно, меньше подвержен перенастройке. Таким образом, выбор того или иного значения параметра регуляризации представляет собой компромисс между требованием эффективности (т.е. высокого процента правильно распознанных объектов контрольной выборки) и устойчивости по отношению к изменениям значений признаков. Кроме того, справедлива следующая

Теорема 2 (О сходимости). Для любой задачи распознавания существует константа $C > 0$, такая что при всех $0 < \delta < C$, решение задачи с регуляризатором $R_\delta(A)$ совпадает с одним из решений задачи (1).

Заключение

Использование регуляризатора позволяет получить единственное, в некотором смысле «наилучшее» решение. В качестве примера рассмотрим задачу дихотомии с помощью построения разделяющей гиперплоскости. Предположим, что классы линейно отделимы. Очевидно, что в этом случае можно построить континуум гиперплоскостей верно классифицирующих все объекты выборки. Несложно видеть, что использование регуляризатора (3) приводит к построению оптимальной разделяющей гиперплоскости, которая единственна [2]. При использовании алгоритмов, основанных на вычислении апостериорных вероятностей принадлежности объекта к классу, можно легко вывести приближенные конструктивные формулы подсчета значения $R_\delta(A)$. В заключение отметим, что за счет асимптотики, определяемой теоремой 1, можно проводить максимизацию функционала в два этапа:

сначала минимизировать первые два слагаемых, а затем остальные. За счет такой процедуры, время обучения можно значительно сократить.

Литература

1. Тихонов А.Н., Арсенин В.Я. Методы решения некорректных задач., 2 изд., М., 1979.
2. Вапник В.Н., Червоненкис А.Я. Теория распознавания образов // М.: Наука, 1974.

Информативность и близость на формулах – знаниях экспертов в конечном классе моделей с метриками

А.А. Викентьев., Р.А. Викентьев

(Новосибирск)

Введение

При решении задач распознавания образов, кластерного и регрессионного анализа важную роль играет информация, полученная от экспертов с учетом некоторых метрических свойств их моделей. Работа является продолжением работ [1-3]. В работе рассматриваются логические высказывания экспертов, записанные в виде логических формул.

Расстояния и их свойства

Будем рассматривать модели только конечной сигнатуры и предполагаем существование в них метрики [2-5].

Определим расстояние между формульными подмножествами (предикатами) в каждой модели $M_i \in Mod_n(\Omega)$, как модифицированную меру их симметрической разности.

Определение 1. Расстоянием между различными формулами $P_k^{M_i}$ и $P_j^{M_i}$, определенными в модели M_i , назовем величину

$$\rho_{M_i}(P_k^{M_i}, P_j^{M_i}) = 1/2(\mu(\tilde{P}_k^{M_i} \Delta \tilde{P}_j^{M_i}) + D(\tilde{P}_k^{M_i}, \tilde{P}_j^{M_i}))$$

Последнее слагаемое D задает расстояние, выраженное через меру соответствующего множества, диаметром которого является расстояние между двумя множествами по Хаусдорфу. Нетрудно понять, что это расстояние D удовлетворяет аксиомам метрики, а первое слагаемое задает псевдометрику и, их комбинация с любыми коэффициентами будет так же метрикой. Эта метрика учитывает не только симметрическую разность, но и степень удаленности друг от друга реализаций предикатов в модели с метрикой.

Расстояние между формулами, определенными на множестве моделей $Mod_n(\Omega)$, определим как среднее на множестве расстояний в классе

моделей:

$$\rho_1(P_k, P_j) = \frac{\sum_{M_i \in \text{Mod}_n(\Omega)} \rho_{M_i}(P_k^{M_i}, P_j^{M_i})}{|\text{Mod}_n(\Omega)|}.$$

Доказана теорема, из которой следует, что предложенное расстояние действительно является метрикой, и некоторые дополнительные свойства введенного расстояния, так и других модификаций ρ_i (в частности заменой 0.5 на любое число из $(0,1]$ в формуле расстояния на модели и модификаций ранее вводимых расстояний учетом добавки D).

Теорема 1. Для любого класса моделей с метрикой для любых формул («знаний» экспертов) ϕ, ψ, χ и для любой функции ρ_i справедливы следующие свойства:

1. $0 \leq \rho_i(\phi, \psi) \leq 1$

2. $\rho_i(\phi, \psi) = \rho_i(\psi, \phi)$ (симметричность).

$$\rho_i(\phi, \psi) \leq \rho_i(\phi, \chi) + \rho_i(\chi, \psi) \text{ (неравенство треугольника).}$$

$\phi \equiv \psi \Leftrightarrow \rho_i(\phi, \psi) = 0$ ($\phi \equiv \psi$ здесь и далее обозначает эквивалентность формул относительно всех моделей, то есть для любой модели M_i верно $\phi^{M_i} \equiv \psi^{M_i}$).

5. $\phi \equiv \neg \psi \Rightarrow \rho_i(\phi, \psi) = 1$

6. $\rho_i(\phi, \psi) = 1 - \rho_i(\phi, \neg \psi) = \rho_i(\neg \phi, \neg \psi)$.

7. $\rho_i(\phi, \psi) = \rho_i(\phi \wedge \psi, \phi \vee \psi)$.

8. $\rho_i(\phi, \neg \phi) = \rho_i(\phi, \psi) + \rho_i(\psi, \neg \phi)$.

Теорема 2. Для любого конечного класса метрических моделей с заданной вероятностной мерой на формульных подмножествах можно ввести на классах неэквивалентных формул финитную отнормированную метрику, учитывающую степень их различия, пересечения и степень разнесенности в каждой модели.

Если на моделях исчисления высказываний введена псевдометрика, то

Теорема 3. Любое счетное множество классов неэквивалентных формул с вероятностями допускает финитную отнормированную метрику, учитывающую меру различия и разброс моделей любой пары формул, и их вероятности.

Меры опровержимости формул

С точки зрения важности информации, сообщенной экспертом, естественно считать, что информативность высказывания (непустого предиката) тем выше, чем меньше число элементов, ему удовлетворяющих (более точно, чем меньше мера, определенная на этом подмножестве). Поэтому как раньше [3] вводится мера опровержимости, которая используется как информативность для выполнимых формул, и доказано, что для нее выполнены все известные свойства.

Теорема 4. Любое счетное множество классов неэквивалентных формул исчисления высказываний с вероятностями допускает конечнозначную функцию опровержимости (информативность), учитывающую финитную отнормированную метрику т.3 и удовлетворяющая всем естественным требованиям [2].

Теорема 5. Любое счетное множество классов неэквивалентных формул исчисления предикатов с вероятностями допускает конечнозначную функцию опровержимости (информативность), учитывающую финитную отнормированную метрику т.2 и удовлетворяющая всем естественным требованиям [3].

Заключение. Полученные результаты остаются справедливыми для любых счетных моделей и измеримых формульных подмножеств, отвечающим знаниям экспертов и с учетом весов моделей. Результаты можно использовать для нахождения усредненных расстояний, мер опровержимости и расстояний между вероятностными высказываниями экспертов. Авторы благодарят профессора Г.С.Лбова за внимание к рассматриваемым вопросам.

Работа выполнена при поддержке РФФИ 01-01-00839.

Литература

1. Лбов Г.С., Старцева Н.Г. Логические решающие функции и вопросы статистической устойчивости решений. Новосибирск: Издательство Института математики, 1999, 212 с.
2. Викентьев А.А., Лбов Г.С. О метризациях булевой алгебры предложений и информативности высказываний экспертов. // Доклады РАН, 1998, т. 361 (2), с.174-176.
3. Викентьев А.А., Коренева Л.Н. К вопросу о расстояниях между формулами, описывающими структурированные объекты. // Математические методы распознавания образов (ММРО-99). РАН ВЦ, Москва, 1999. С.151-154.

4. Ершов Ю.Л., Палютин Е.А. Математическая логика. М.: Наука, 1991, 336 с.
5. Gaifman H. Concerning measures in the first order calculi. // Israel Journal of Mathematics, v. 2 (1), 1964, p. 1-18.

О комбинаторном подходе к оценке качества обучения алгоритмов

К.В. Воронцов

(Москва)

В статистической теории Вапника-Червоненкиса качество обучения алгоритмов определяется с помощью функционала равномерной сходимости частоты ошибок к их вероятности [1]. Известные верхние оценки этого функционала сильно завышены, что приводит к требованию чрезмерно длинных обучающих выборок (10^5 – 10^7 объектов), либо к переупрощению алгоритмов. До сих пор остается актуальной задача получения более точных оценок и поиска наиболее адекватного способа формализации самого понятия качества обучения.

Один из альтернативных подходов состоит в том, чтобы определять качество обучения с помощью *комбинаторных* функционалов, основанных на принципе скользящего контроля. Для таких функционалов справедливы оценки, аналогичные статистическим, и даже более точные [2]. При этом требования случайности, независимости и одинаковой распределенности выборки оказываются избыточными, достаточно лишь предположения о симметричности (инвариантности относительно всевозможных перестановок выборки) функционала качества. Фактически, это слабая форма гипотезы независимости, при которой ограничение переносится с исходных данных на функционал качества.

Комбинаторный подход приводит к более точным оценкам, так как он позволяет учитывать свойства заданной конечной совокупности объектов и *метода обучения* (под методом обучения понимается способ построения алгоритма по произвольной обучающей выборке). Полученные оценки выражаются через функцию роста не всего семейства алгоритмов, а только его конечного *локального подсемейства*, состоящего из алгоритмов, реально получаемых в результате обучения. Эффект локализации возникает в любой задаче, как только фиксируются обучающая выборка и метод обучения.

Комбинаторные функционалы, в отличие от вероятностных, допускают эффективное измерение. Это позволяет оценить также и *эффективную локальную ёмкость* метода обучения. Метод её оценки существенно проще измерения *эффективной ёмкости* семейства алгоритмов по Вапнику [4].

Сравнение комбинаторных и вероятностных оценок качества позволяет выделить три основные причины их завышенности.

Первая причина — пренебрежение эффектом локализации. Ёмкость локального подсемейства может оказаться существенно меньше ёмкости всего семейства.

Вторая причина — погрешность экспоненциальной верхней оценки комбинаторного множителя, единственная цель которой — получение компактной окончательной формулы. Возникающая при этом относительная погрешность увеличивается с ростом длины выборки. Если ставить целью получение оценок, непосредственно применимых на практике, то придется смириться с необходимостью вычисления или табулирования достаточно сложных комбинаторных выражений.

Третья причина — погрешность разложения функционала качества в произведение локальной функции роста и комбинаторного множителя. Эта причина представляется наиболее существенной, поскольку она вызвана переходом от анализа качества к анализу сложности и связана с самой природой сложностных оценок. Она в одинаковой степени относится к вероятностным и комбинаторным оценкам, включающим функцию роста.

Сложность семейства алгоритмов, и даже его локального подсемейства, представляется слишком грубой характеристикой, которая всегда оценивает «худший случай», не учитывая специфических особенностей конкретной выборки, метода обучения и самой восстанавливаемой зависимости. Комбинаторный подход существенно упрощает анализ различного рода априорной информации. В докладе сообщается о двух таких результатах.

Для метода ближайшего соседа получено точное выражение функционала скользящего контроля. В этом случае качество обучения полностью определяется «профилем компактности» выборки, который можно рассматривать как количественное выражение гипотезы компактности классов.

Достаточно точная оценка получена также для задач классификации с монотонной или почти монотонной зависимостью. В этом случае качество обучения определяется «профилем монотонности» выборки, который можно рассматривать как априорную информацию о плотности отношения порядка вблизи границы классов. Полученная оценка всегда не тривиальна (не превышает единицы), даже на малых выборках [3].

Работа поддержана Российским фондом фундаментальных исследований (№ 02-01-00325, № 01-07-90242) и Фондом содействия отечественной науке. Развернутый вариант статьи: www.ccas.ru/frc/papers/voron03qualdan.pdf.

Литература

1. Вапник В. Н., Червоненкис А. Я. Теория распознавания образов. — М. Наука, 1974.
2. Воронцов К. В. Качество восстановления зависимостей по эмпирическим данным // ММРО–7: Тез. докл. — Пущино, 1995.

3. Воронцов К. В. Оценка качества монотонного решающего правила вне обучающей выборки // ИОИ: Тез. докл. — Симферополь, 2002.
4. Vapnik V., Levin E., Cun Y. L. Measuring the VC-dimension of a learning machine // Neural Computation. — 1994. — Vol. 6, no. 5. — Pp. 851–876.

Последовательный алгоритм распознавания объектов при стохастических исходных данных

Ю.Е. Гагарин

(Калуга)

Последовательный алгоритм распознавания объектов заключается в том, что решение о принадлежности объекта к какому-либо классу принимается после измерения некоторого набора признаков. С получением очередного признака производится сравнение с некоторыми заранее определенными границами и принимается решение либо о принадлежности объекта к соответствующему классу, либо производится измерение следующего признака. Рассмотрим процедуру распознавания, когда множество объектов разделено на два класса ω_1 и ω_2 . На каждом шаге последовательного алгоритма определяется отношение условных плотностей распределения вероятностей (УПРВ) $\lambda_n = f_1(x_i)/f_2(x_i)$, где x_i – набор признаков $i = \overline{1, n}$. При этом наблюдения производятся пока выполняется условие

$$B < \lambda_n < A.$$

Наблюдения прекращаются, и принимается решение о принадлежности распознаваемого объекта классу ω_1 , если $\lambda_n \geq A$ и решение о принадлежности классу ω_2 , если $\lambda_n \leq B$. A и B называются верхним и нижним порогами. Пороги A и B выбираются исходя из допустимых значений ошибок первого Q_1 и второго рода Q_2 [1].

Исходные данные в задачах распознавания объектов являются результатами конкретных экспериментов и содержат случайные ошибки, которые необходимо учитывать. В последовательном алгоритме исходными данными являются значения признаков x_i распознаваемого объекта. По этим значениям оцениваются УПРВ, которые также будут иметь некоторые погрешности. С учетом этих погрешностей отношение УПРВ примет вид:

$$\lambda_n \pm \Delta \lambda_n = \frac{f_1(x_i) \pm \Delta f_1}{f_2(x_i) \pm \Delta f_2}.$$

Для принятия решения с помощью последовательного алгоритма при

известном параметрическом виде УПРВ возникает необходимость оценивания параметров УПРВ. Принимая во внимание случайный характер значений признаков, исходная модель для оценивания параметров УПРВ имеет вид:

$$\begin{cases} y_i = f(x_i, \Theta) + \varepsilon_i, \\ x_i = \xi_i + \delta_i, i = \overline{1, n} \end{cases}$$

где ε_i и δ_i – погрешности значений УПРВ и значений признаков соответственно; ξ_i – неизвестные (истинные) значения признаков; Θ – вектор неизвестных параметров УПРВ.

Примем, что погрешности измерений ε_i и δ_i – нормально распределенные случайные величины с нулевыми средними значениями, с дисперсиями $\sigma^2(y_i)$ и $\sigma^2(x_i)$ соответственно и коэффициентом корреляции $\rho_i = 0$. Для получения несмещенных оценок параметров Θ можно воспользоваться методами конъюгентного анализа [2]. При использовании данных методов оценки параметров Θ находятся из условия минимума функционала:

$$F = \frac{1}{2} \sum_{i=1}^n \left[\frac{(y_i - f(x_i, \Theta))^2}{\sigma^2(y_i)} + \frac{(x_i - \xi_i)^2}{\sigma^2(x_i)} \right].$$

Кроме оценок параметров Θ определим и дисперсии оценок $D(\Theta)$. Это можно сделать из матрицы, обратной матрице M , элементы которой вычисляются по формуле [3]:

$$M_{kt} = - \frac{\partial^2 F}{\partial \theta_k \partial \theta_t} \Big|_{\Theta = \hat{\Theta}}$$

где $k, t = \overline{1, S}$; S – количество параметров УПРВ.

По известным оценкам параметров и их дисперсиям можно определить УПРВ и их погрешности Δf_j . Погрешности УПРВ окажут влияние и на ошибки первого и второго рода

$$Q_1 \pm \Delta Q_1 = \int_{G_2} [f_1(x, \Theta) \pm \Delta f_1(x, \Theta)] dx,$$

$$Q_2 \pm \Delta Q_2 = \int_{G_1} [f_2(x, \Theta) \pm \Delta f_2(x, \Theta)] dx,$$

где G_1 и G_2 – области в признаковом пространстве, соответствующие классам ω_1 и ω_2 .

Значения A и B не будут определяться однозначно, а будут иметь некоторые погрешности $A \pm \Delta A$ и $B \pm \Delta B$, т.е. кроме точечных значений порогов вычисляются и их интервальные значения. Интервальные значения верхнего и нижнего порогов будут определяться исходя из соотношений:

$$A \pm \Delta A \leq [1 - (Q_1 \pm \Delta Q_1)] / (Q_2 \pm \Delta Q_2),$$

$$B \pm \Delta B \geq (Q_1 \pm \Delta Q_1) / [1 - (Q_2 \pm \Delta Q_2)].$$

В результате принятие решений с помощью последовательного алгоритма и с учетом погрешности исходных данных, в отличие от традиционного подхода может потребовать дополнительного набора признаков. Количество дополнительных признаков зависит от точности их измерения. Однако определение интервальных значений порогов увеличивает достоверность принятия решений.

Работа выполнена при поддержке Российского фонда фундаментальных исследований и Администрации Калужской области (грант № 02-01-96023).

Литература

1. Горелик А.Л., Скрипкин В.А. Методы распознавания. –М.: Высшая школа, 1984. 208 с.
2. Грешилов А.А. Анализ и синтез стохастических систем. Параметрические модели и конfluenceный анализ. –М.: Радио и связь, 1990. 320 с.
3. Гагарин Ю.Е. Об определении интервальных оценок среднего риска при случайных исходных данных в задачах распознавания // Труды МГТУ им. Н.Э. Баумана, 1999. №575. С. 80-86.

Дифференцируемость функции уклонения в R^n

С.А. Гальперин
(Екатеринбург)

Вопрос о дифференцируемости функции уклонения

$d_E(x) = \sup_{y \in E} |x - y|$ от компакта $E \subseteq R^n$ возникает сразу в нескольких

областях математики (более подробно см. [1-3]). В распознавании образов эта проблема интересна в связи с задачей о нахождении в некотором смысле наилучшего представителя заданного множества E . Одним из таких представителей является чебышевский центр множества E – точка, приносящая инфимум $d_E(x)$. В работе автора [1] было доказано достаточное условие k -дифференцируемости функции уклонения от компактного множества с k -гладкой границей на плоскости ($k \geq 2$). В данной статье результат обобщается на евклидовы пространства произвольной размерности.

Теорема Пусть $E \subseteq R^n$ – компакт, $\partial E \in C^k$, $k \geq 2$, $U \subseteq R^n$ – открыто, и

- Каждая $x \in U$ имеет единственную дальнейшую точку E
- В U нет центров главных кривизн ∂E

Тогда $d_E \in C^k(U)$.

Доказательство: Пусть $f(z)$ – дальнейшая от $z \in U$ точка E . Рассмотрим произвольную $A \in U$, и поместим $f(A)$ в центр координат. Так как ∂E – гладкое многообразие, мы можем выбрать направления координатных осей и параметризацию границы E так, что некоторая окрестность $f(A) = 0$ в

∂E будет даваться как $\left\{ (t_1, t_2, \dots, t_{n-1}, \varphi(t_1, t_2, \dots, t_{n-1})) \mid \sum_{i=1}^{n-1} t_i^2 < r^2 \right\}$,

где $r > 0$, $\varphi \in C^k$, $\varphi(0) = 0$, и $\text{grad } \varphi(0) = 0$ (т.е. n -ная координатная ось ортогональна ∂E в 0). Более того, будем считать, что n -ная координатная ось коллинеарна внутренней нормали к ∂E (иначе применим симметрию). Дальнейшим вращением первых $n-1$ координатных осей перейдем к главной системе координат поверхности в нуле.

Напомним, что в главной системе координат гессиан $D^2\varphi(0)$ диагонален с главными кривизнами κ_i поверхности ∂E в точке 0 на

главной диагонали, $i = 1..n-1$.

Рассмотрим шар B с центром A и радиусом $d_E(A)$, и пусть S - его граница. Поскольку $\partial E \subseteq E \subseteq B$ и $f(A) \in \partial E \cap S$, S касается ∂E в $f(A)$. Следовательно, радиус $A - f(A)$ коллинеарен внутренней нормали к ∂E в 0 , так что $A = (0, 0, \dots, 0, y_0)$ для некоторого $y_0 > 0$.

Поскольку S и ∂E имеют контакт по крайней мере первого порядка в 0 и $\partial E \subseteq B$, κ_i не могут быть меньше кривизны S , равной $\frac{1}{y_0}$. По

условию, A - не центр главной кривизны, откуда $\kappa_i > \frac{1}{y_0}$, $i = 1..n-1$.

Известно, что единственность дальнейшей точки влечёт за собой непрерывность f в U (см., например, Лемму 4 [3]). Следовательно, существует окрестность $V \subseteq U$ такая, что $A \in V$, и $\forall x = (x_1, \dots, x_n) \in V$ $f(x) = (t(x), \varphi(t(x)))$ для некоторой непрерывной функции $t(x) = (t_1(x), t_2(x), \dots, t_{n-1}(x))$, $|t(x)| < r$. Так как вектор $t(x)$ приносит

максимум функции $\left[\sum_{i=1}^{n-1} (t_i - x_i)^2 + (\varphi(t_1, \dots, t_{n-1}) - x_n)^2 \right]$ для каждой

фиксированной точки $(x_1, \dots, x_n) \in V$, получаем

$$\frac{\partial}{\partial t_i} \left[\sum_{j=1}^{n-1} (t_j - x_j)^2 + (\varphi(t) - x_n)^2 \right] = 2(t_i - x_i) + 2\varphi'_{t_i}(t)(\varphi(t) - x_n) = 0$$

при $t_i = t_i(x)$, $i = 1..n-1$.

Покажем, что уравнения $F_i(x, t) = 2(t_i - x_i) + 2\varphi'_{t_i}(t)(\varphi(t) - x_n) = 0$ неявно определяют функции $t_i = t_i(x)$, $i = 1..n-1$ в некоторой окрестности A . В самом деле, так как $\varphi \in C^k(B_r)$, где B_r - $(n-1)$ -мерный шар радиуса r с центром в 0 , то каждая F_i непрерывно дифференцируема на $V \times B_r$ $(k-1)$ раз. Кроме того, $F_i(A, 0) = 0$ для каждого i . Остаётся

лишь показать, что Якобиан $\frac{D(F_1, \dots, F_{n-1})}{D(t_1, \dots, t_{n-1})} \neq 0$ в $(A, 0)$. Так как

$$(F_i)'_{t_i}(x, t) = 2 \left(1 + \varphi''_{t_i t_i}(t)(\varphi(t) - x_n) + \varphi'_{t_i}{}^2(t) \right),$$

получаем

$$\begin{aligned} \frac{(F_i)'_{t_i}(A, 0)}{2} &= 1 + \varphi''_{t_i t_i}(0)(\varphi(0) - y_0) + \varphi'_{t_i}{}^2(0) = \\ &= 1 - \varphi''_{t_i t_i}(0)y_0 = 1 - \kappa_i y_0 < 0, \end{aligned}$$

так что на главной диагонали матрицы Якоби стоят ненулевые числа. Но эта матрица диагональна, поскольку

$$(F_i)'_{t_j}(x, t) = 2 \left(\varphi''_{t_i t_j}(t)(\varphi(t) - x_n) + \varphi'_{t_i}(t)\varphi'_{t_j}(t) \right)$$

и $(F_i)'_{t_j}(A, 0) = 2 \left(\varphi''_{t_i t_j}(0)(\varphi(0) - x_n) + \varphi'_{t_i}(0)\varphi'_{t_j}(0) \right) = 0$ при $i \neq j$.

Следовательно, искомый Якобиан не равен нулю.

По теореме о неявной функции, в некоторой окрестности W точки A существует единственная функция $t(x) \in C^{k-1}$. По теореме 2.4 [1],

$\text{grad } d_E(x) = \frac{x - f(x)}{d_E(x)} = \frac{x - (t(x), \varphi(t(x)))}{d_E(x)}$ есть отношение двух C^1 -

функций, а, значит, $\text{grad } d_E(x) \in C^1(W)$, т.е. $d_E(x) \in C^2(W)$.

Применяя это рассуждение ещё $k-2$ раза, получаем $d_E(x) \in C^k(W)$.

Поскольку A была выбрана из U произвольно, $d_E(x) \in C^k(U)$. Q.E.D.

Работа выполнена при поддержке РФФИ (грант 03-0100241)

Литература

1. Galperin S., Differentiability of the Farthest-Point Distance Function // Proceedings of the IASTED International Conference on Automation, Control and Information Technology (2002), С. 539-543.
2. Laugesen R.S., Pritsker I.E., Potential Theory of the Farthest-Point Distance Function, Can. Math. Bull. (to appear).
3. Motzkin T.S., Straus E.G., and Valentine F.A. The Number of Farthest Points, Pacific J. Math. 3 (1953), С. 221-232.

О регулярности и разрешимости задач распознавания с равномошными классами

Ю.И. Горелов

(Тула)

Рассматривается подкласс задач распознавания, о которых априори известно, что мощность любого из представленных в исходной информации подмножеств допустимых объектов, принадлежащих произвольному классу (в смысле теории распознавания образов), равна произвольному заранее фиксированному или вычисляемому по мощности набора прецедентов натуральному числу. Задачи такого типа встречаются при рассмотрении методов синтеза прогнозирующих фильтров и восстановления эмпирических зависимостей в рамках теории распознавания образов [4]. Отметим, что изучение задач распознавания с равномошными классами с позиций алгебраической теории алгоритмов преобразования информации безусловно представляет самостоятельный теоретический и практический интерес.

В рамках алгебраической теории [1] проведен теоретический анализ для двух случаев задания множества финальных информации: случая двухэлементного множества финальных информации и случая, когда отрицанию отношения принадлежности допустимого объекта любому из классов в множестве финальных информации поставлен в соответствие единственный элемент.

На основании аналогов теоремы Гейла-Райзера [2] показано, что в обоих случаях требование равномошности классов приводит к тому, что информационная матрица задачи распознавания не может быть произвольным элементом множества пространства прямоугольных матриц над множеством финальных информации. Поэтому орбита регулярной задачи распознавания с равномошными классами не совпадает с орбитой регулярной задачи распознавания, рассматриваемой в общем случае [3].

Найдены достаточные условия полноты задачи распознавания с равномошными классами и универсальными ограничениями специального вида относительно модели алгоритмов, удовлетворяющим этим универсальным ограничениям. Показано, что эти универсальные ограничения описывают информацию о различного рода однородностях данных об объектах и классах, а поэтому являются симметрическими. Они могут быть формально описаны симметрическими категориями [3] специального вида, которые как показано в работе являются полными и допустимыми.

Кроме того в работе найдены описания одноэлементных баз этих симметрических категорий, что автоматически [3] позволяет выписать критерии регулярности различного типа задач распознавания с равномошными классами.

Получены описания «минимальных» моделей алгоритмов распознавания,

которые полны в смысле разрешимости всех регулярных задач.

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований грант № 03-01-00810 .

Литература

1. Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики. -М.: Наука, 1978. - Вып.33. - С. 5-68.
2. Оре О. Теория графов. - М.: Наука, 1980. - 336 с.
3. Рудаков К.В. Об алгебраической теории универсальных и локальных ограничений для задач классификации // Распознавание, классификация, прогноз. М.: Наука, 1989. С. 176-201.
4. Vasilyev V.I., Gorelov Yu.I. The Synthesis of Forecasting Filters by Pattern Recognition Learning Methods // Pattern Recognition and Image Analysis, Interperiodica, 1997, vol.7, №3, pp.353 - 368.

Определение вероятности ошибки распознавания с восстановлением её априорного распределения

С.И. Гуров, О.Ф. Уткина

(Москва)

Предлагается новый метод определения интервальных оценок неизвестных величин, в частности, ошибок классифицирующих алгоритмов. Идея метода состоит в восстановлении априорного распределения на основе приравнивания частотной и байесовской точечных оценок. Требование совпадения оценок, полученных разными методами, представляется вполне оправданным и предлагаемый подход естественно назвать «*принципом согласованности*». Полученное априорное распределение определяет апостериорное, которое и используется для получения интервальных оценок.

Против применения предлагаемого принципа могут быть выдвинуто возражение, связанное с тем, что часто оцениваемые параметры являются неизвестными, но фиксированными (неслучайными), и поэтому при их нахождении применимы лишь классические частотные методы. Однако, если придерживаться т.н. «субъективного» подхода в статистических задачах оценивания, (считать, что априорное распределение является мерой нашего незнания), то применение байесовского подхода является оправданным.

Пусть плотность априорного распределения $f_{a_pri}(\theta; \lambda^*)$ искомой величины θ определено с точностью до параметра λ^* – фиксированного, но неизвестного. Пусть также $L(\theta, x)$ – функция правдоподобия, где x – вектор наблюдаемых значений случайных величин. Тогда плотность апостериорного распределения величины θ записывается как $f_{a_post}(\theta; \lambda^*, x)$. Найдём частотную точечную оценку истинного значения θ^* , например

оценку θ_L максимального правдоподобия: $\theta_L = \arg \max L(\theta, x)$. Бейесовской оценкой θ_B величины θ^* при любой выпуклой функции потерь будет математическое ожидание μ_{a_post} апостериорного распределения, т.е. $\theta_B = \mu_{a_post}$ [2]. Ясно, что θ_L и θ_B суть функции от x и (λ, x) соответственно. Приравняем рассмотренные точечные оценки и решим полученное уравнение $\theta_L = \theta_B$ относительно λ . В результате получим значение $b = b(x)$, являющееся оценкой истинного значения параметра λ^* . Величина b полностью определяет единую точечную оценку $\theta_c = \theta_c(\lambda)$, а также априорное и апостериорное распределения θ . Полученное априорное распределение с плотностью $f_{a_pri}(\theta; \lambda)$ естественно назвать *наиболее правдоподобным*. При «хороших» свойствах λ (несмещённость θ_c , приемлемое значение дисперсии $D(\theta_c)$) плотность апостериорного распределения $f_{a_post}(\theta; \lambda, x)$ или значение θ_u можно использовать для получения интервальных оценок величины θ^* [3].

Продемонстрируем применение изложенного метода к оценке малой величины p^* , понимая под p^* фиксированную, но неизвестную вероятность ошибки построенного алгоритма классификации. Пусть в результате экзаменационного контроля алгоритм ошибся при классификации $m > 0$ (случай нуль-события не рассматриваем) прецедентов из $n > 1$. Понятно, что здесь m – случайная величина, распределённая по биномиальному закону, а n – неслучайный параметр эксперимента. Точечной оценкой максимального правдоподобия p_L величины p^* будет являться относительная частота ошибки m/n . В известной монографии [2] бейесовскую оценку p_B малой величины p^* предложено представлять в виде $(m+1)/(n+b+1)$, где $b > 1$ и достаточно велико (таким образом, имеем $\lambda = b$), однако не дано ни обоснований такому выбору, ни предположений относительно того или иного метода определения значения параметра b .

Предложенная бейесовская оценка является математическим ожиданием β -распределения $Be(m+1, n-m+b)$. Из условия $p_L = p_B$ находим $b = (n-m)/m$. С учётом вида функции правдоподобия $L = p^m(1-p)^{n-m}$ плотность априорного распределения p^* естественно представить в виде $Be(1, b)$ [3, 4]. Таким образом, и априорное, и апостериорное распределения полностью определены.

Используя известные соотношения, изложенные, например, в [1], можно показать, что (1) значения $b = (n-m)/m$ и $p = 1/(b+1)$ являются несмещёнными точечными оценками истинных значений b^* и p^* соответственно, и (2) несмещённой оценкой дисперсии $D(p)$ будет являться величина $b/[b(b+1)^2(n-1)]$.

Заметим, что в рассмотренном нами случае выполняются равенства

$$\mu_{a_post} = \arg \max L = p = 1/(b+1) = \mu_{a_pri}.$$

Ясно также, что в нашей задаче значение b будет «существенно»

превосходить I : при уровне ошибок в 20% (вряд ли алгоритмы классификации с большим процентом ошибок представляют практический интерес) имеем $b = 4$.

Далее, при достаточно больших значениях b численно решая относительно p уравнение

$$I_p(m+1, n-m+b) = \eta,$$

где I_p – неполная β -функция, а η – выбранное значение коэффициента доверия, получаем значение p^+ , определяющее односторонний интервал $(0, p^+)$, в котором с коэффициентом доверия η находится истинное значение вероятности ошибки p^* .

При относительно небольших значениях b можно известными методами [1, 3] находить двусторонние неймановские доверительные интервалы: их границы p^+ и p^- суть соответственно решения уравнений (здесь $0,5 \leq P < 1$)

$$I_p(m+a-1, n-m+b) = 1 - P = (1-\eta)/2 \quad \text{и}$$

$$I_p(m+a, n-m+b-1) = P = (1+\eta)/2.$$

Нетрудно показать, что, с одной стороны, априорное распределение $Be(l, b)$ доставляет максимальные по величине интервалы среди всех β -распределений $Be(a, b)$ при $l \leq a, b$ (т.е. мы рассматриваем «наихудший» случай), а с другой – описанные интервальные оценки лучше получаемых традиционно. Для разработанного согласованного метода была составлена компьютерная программа расчёта границ доверительных интервалов при различных n, m и η ($\eta = 0,90 \dots 0,99$).

Важно отметить, что предлагаемый метод пригоден в практически важных случаях малого числа n прецедентов и/или редких событий.

Работа выполнена при финансовой поддержке РФФИ (код проекта 01-01-00885).

Литература

1. Кендал М., Стюарт А. Статистические выводы и связи. – М.: Наука, 1973.
2. Леман Э. Теория точечного оценивания. – М.: Наука, 1991.
3. Гуров С. Оценка надежности классифицирующих алгоритмов. – М.: Издательский отдел ф-та ВМиК МГУ, 2002.
4. Гуров С. Как оценить надёжность алгоритма классификации // Таврический Вестник информатики и математики. Вып. 1, 2003. – Симферополь: КНИЦ. – С. 27-56.

Спектральные методы в задачах обработки информации

Ф.Ф. Дедус

(Пушино)

Повышение эффективности работы сложных технических систем зависит в значительной степени от скорости, надежности и точности переработки больших потоков измерительной информации при обеспечении повышенной помехозащищенности и возможности максимально использовать как цифровые расчеты, так и аналитические приемы преобразования информационных массивов данных.

Наиболее полно, на наш взгляд, указанным требованиям отвечает разработанный нами обобщенный спектрально-аналитический метод обработки информационных массивов данных (ОСАМ). Он относится к категории комбинированных численно-аналитических методов и в полной мере использует преимущества как числовых расчетов на современных ЭВМ, так и аналитических преобразований и выводов, выполняемых соответствующими специалистами, и приводящий наиболее быстро к получению требуемых оценок и характеристик [1].

В предлагаемом докладе показано развитие метода, обусловленное необходимостью решения ряда важных прикладных задач.

К ним относятся, прежде всего, следующие три направления.

1. Существенно возросли требования увеличения точности аналитического описания кривых, заданных большими массивами данных.

Это относится, прежде всего, к задачам аналитического описания геофизических и сейсмических данных, случайных процессов различной физической природы, для которых потребовалось разработать алгоритмы и программы для вычисления до 500 коэффициентов разложения. Особо выделяются сигналы, описывающие результаты исследования различных образцов на установке ядерно-магнитного резонанса. Массив однократного эксперимента на такой установке достигает 3000 – 4000 отсчетов. Сейчас имеется возможность вычислять на персональном компьютере средней мощности до 2000 – 3000 коэффициентов разложения за весьма короткое время. Специалисты уверенно утверждают, что имеется возможность еще более увеличить число коэффициентов разложения по базисам Чебышева и Лагерра.

2. Решение ряда технических задач связано с необходимостью получения с требуемой точностью нескольких первых производных от исследуемых сигналов или процессов.

Показано, что необходимые производные от зашумленных сигналов или процессов целесообразно получать по результатам их спектрального анализа при разложении в ортогональный ряд по классическим ортогональным базисам. Причем требуемый результат можно получать как подбором соответствующих ортонормированных базисов, обладающих повышенным

эффектом сглаживания помех, так и увеличением глубины разложения. Приведены примеры решения поставленной задачи.

3. В настоящее время задача объективного контроля исправности сложных технических систем, особенно динамических систем управления полетом летательных аппаратов, является весьма ответственной и актуальной.

До сих пор широко используется метод контроля исправности динамических систем, основанный на анализе показаний соответствующих датчиков и последующего принятия решений специальной ЭВМ, к которой подключены все датчики состояния параметров.

Считаем, что оценивать динамические характеристики систем управления целесообразно по результатам анализа их обобщенных динамических показателей. Реализация предлагаемого метода контроля предполагает использование специально выбранной обобщенной динамической характеристики системы управления, в которой отображаются влияния всех оцениваемых параметров в целом.

В динамических системах к таким обобщенным характеристикам относятся переходные процессы как реакции на специальный тестовый или типовой рабочий сигнал. Объективные сведения о состоянии динамических показателей сложных систем можно получить также в результате анализа их частотных характеристик. Тем не менее, предпочтительнее методы, основанные на анализе выходных временных характеристик систем, обработка которых легко поддается автоматизации.

К таким сигналам относят, прежде всего, реакцию системы на импульсное воздействие, когда на ее вход подается единичный импульс. При этом выходной сигнал называют импульсной переходной характеристикой, которая полностью отображает особенности ее динамических свойств. Часто в качестве тестового сигнала используют также единичное скачкообразное воздействие. В этом случае реакцию системы называют переходной характеристикой.

Выбор критерия контроля исправности при этом должен учитывать наличие высокочастотных помех, которые неизбежно будут накладываться на анализируемую выходную характеристику.

В этой ответственной ситуации следует использовать интегральные критерии оценки исправности динамических систем по их обобщенной характеристике. Указанные оценки, вычисленные на ЭВМ, представляют собой конкретные числа, которые называют обобщенными динамическими показателями, объективно и исчерпывающе отображающие динамические свойства системы в целом.

Формирование конкретных интегральных оценок динамики определяется требованиями к качеству динамики систем управления данного класса, а также выбором метрик, определяющих соответствующие метрические

пространства, изучаемые в функциональном анализе, наиболее чувствительных к возможным изменениям динамических свойств системы. Проводимые исследования выполняются при финансовой поддержке РФФИ (номера проектов: 01-07-97060, 01-07-90317, 01-01-00894).

Литература

1. Ф.Ф.Дедус, С.А.Махортых, М.Н.Устинин, А.Ф.Дедус. Обобщенный спектрально-аналитический метод обработки информационных массивов.// М. Машиностроение. 1999. с.356.
2. А.Н.Колмогоров, С.В.Фомин. Элементы теории функций и функционального анализа.// М. Наука. 1968.

Экспериментальное исследование алгоритмов построения неприводимых покрытий булевых матриц

Е.А. Демьянов, Е.В. Дюкова, А.С. Инякин
(Москва)

Одной из основных проблем при конструировании дискретных процедур распознавания является проблема эффективного поиска информативных фрагментов описаний обучающих объектов. Задача является трудной в вычислительном плане и как правило сводится к задаче построения неприводимых покрытий булевых матриц, которая может быть сформулирована также как задача преобразования конъюнктивной нормальной формы монотонной булевой функции в сокращенную дизъюнктивную нормальную форму.

Целью работы является экспериментальное исследование ранее известных алгоритмов построения неприводимых покрытий булевых матриц [1, 2] и новых алгоритмов, предложенных авторами доклада [3, 4, 5]. Рассматриваются алгоритмы, ориентированные на специальный вид матриц (в основном имеется ввиду соотношение между числом строк и столбцов матрицы), и «универсальные» алгоритмы, эффективные практически при любом соотношении между числом строк и числом столбцов матрицы.

В случае, когда число столбцов матрицы существенно превосходит число строк, достаточно эффективным является асимптотически оптимальный алгоритм [1], обозначаемый далее АО1. Алгоритм основан на построении всех единичных подматриц исходной матрицы. Его эффективность следует из того, что в рассматриваемом случае число неприводимых покрытий почти всегда асимптотически совпадает с числом единичных подматриц.

В [3] предложена модификация алгоритма АО1, обозначаемая далее АО2. В данной модификации строятся не все единичные подматрицы, а только те, которые порождают неприводимые покрытия. Указанные подматрицы строятся с полиномиальной временной задержкой относительно размеров исходной матрицы. Алгоритм АО2 имеет более широкую область

применения по сравнению с алгоритмом АО1.

В случае, когда число строк матрицы существенно превосходит число столбцов, ранее в основном использовался алгоритм из [2], обозначаемый далее СК. В этом алгоритме используется идея расшифровки монотонной булевой функции.

В [4] предложен новый алгоритм, использующий «дополнительную» матрицу (фактически осуществляется поиск максимальных граней в некотором подмножестве единичного куба, которое определяется по множеству строк исходной матрицы), обозначаемый далее ДМ.

В [5] предложен «универсальный» алгоритм, основанный на удалении охватывающих столбцов, обозначаемый далее УОС. На каждом шаге алгоритма за полиномиальное (относительно размеров исходной матрицы) время строится набор столбцов, не содержащий охватывающих столбцов. Указанная процедура позволяет существенно сократить число просматриваемых наборов столбцов и за счет этого достигается высокое быстродействие.

Перечисленные выше алгоритмы были реализованы на языке С++ для ЭВМ на базе процессоров семейства x86. Для сравнения алгоритмов была проведена серия экспериментов на случайных матрицах размера $m \times n$ с равновероятным появлением 0 и 1. Для каждой пары (m, n) обсчитывалось по 10 матриц. Алгоритмы сравнивались в случаях $m=n$, $m < n$ и $m > n$. Результаты экспериментов отражены в таблицах 1-3 и соответствующих диаграммах 1-3.

Таблица 1. (Случай $m=n$).

Размеры матрицы	Среднее время счета (мсек)			Отношение времен счета		
	АО1	АО2	УОС	АО2/АО1	УОС/АО1	УОС/АО2
20x20	48	20	20	0,417	0,416	1
22x22	97	32	24	0,330	0,247	0,75
24x24	215	72	31	0,335	0,144	0,430
26x26	389	126	48	0,324	0,123	0,380
28x28	610	252	70	0,413	0,114	0,277
30x30	1 456	485	121	0,333	0,083	0,249
32x32	2 289	849	192	0,371	0,083	0,226
34x34	4 323	1 310	343	0,303	0,079	0,261
36x36	7 080	2 148	526	0,303	0,074	0,244
38x38	12 334	3 805	919	0,308	0,074	0,241
40x40	19 879	6 545	1566	0,329	0,078	0,239
45x45	81 083	21 177	4374	0,261	0,053	0,206
50x50	264 800	68 679	13440	0,259	0,050	0,195

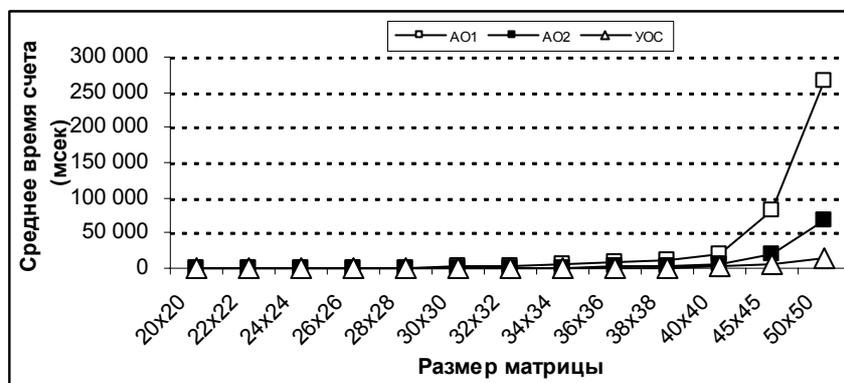


Диаграмма 1.

Таблица 2. (Случай $m < n$).

Размеры матрицы mхn	Среднее время счета (мсек)			Отношение времен счета		
	AO1	AO2	YOC	AO2/AO1	YOC/AO1	YOC/AO2
30x30	1 456	485	150	0,333	0,103	0,309
30x40	5 744	2 380	595	0,414	0,103	0,25
30x50	23 413	8 141	2210	0,348	0,094	0,271
30x60	53 234	25 229	6467	0,474	0,121	0,256
30x70	129 538	59 575	14282	0,460	0,110	0,239
30x80	228 270	154 685	24601	0,678	0,107	0,159
30x90	502 278	275 876	63129	0,549	0,125	0,228
30x100	938 617	600 283	107275	0,640	0,114	0,178

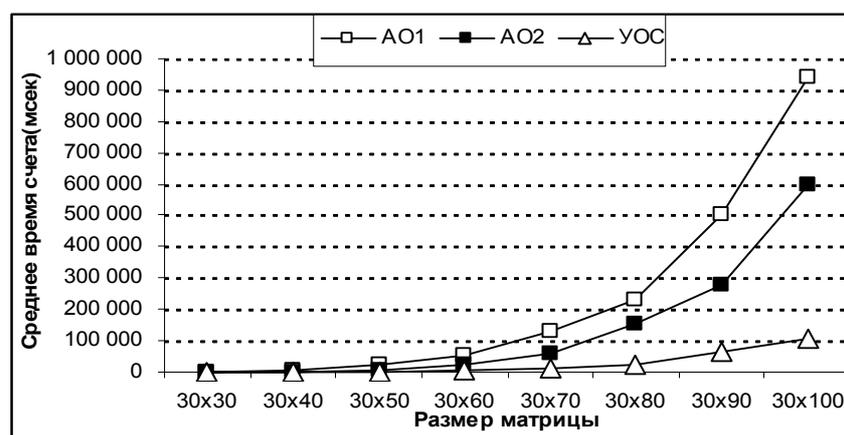


Диаграмма 2.

Таблица 3. (Случай $m > n$).

Размеры матрицы	Среднее время счета (мсек)			Отношение времен счета		
	AO1	AO2	УОС	AO2/AO1	УОС/AO1	УОС/AO2
30x30	1 456	485	150	0,333	0,103	0,309
40x30	5 734	1 078	275	0,188	0,047	0,255
50x30	18 847	2 583	426	0,137	0,022	0,164
60x30	42 757	4 236	695	0,099	0,017	0,164
70x30	125 420	5 655	945	0,045	0,008	0,167
80x30	235 072	9 732	1 579	0,041	0,006	0,162
90x30		13 178	2 030			0,154
100x30		17 497	2 714			0,155

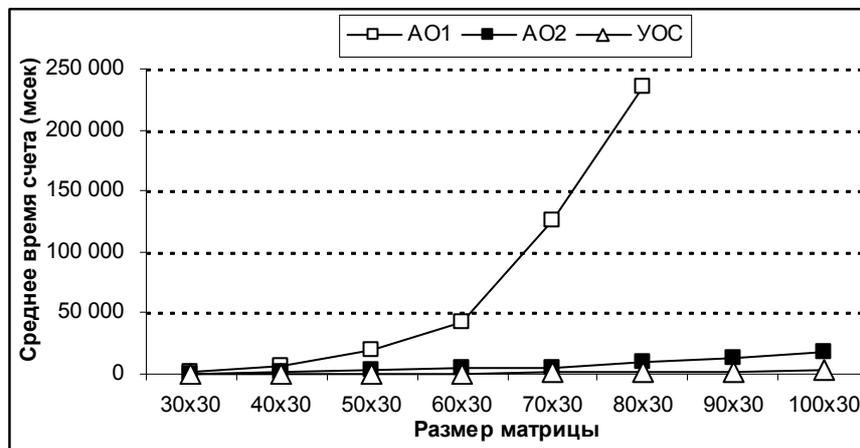


Диаграмма 3.

В случае небольшого числа столбцов матрицы и очень большого числа строк ($m > 500$, $n < 19$), наиболее эффективным оказался алгоритм ДМ.

Таким образом, применение новых методов позволяет существенно сократить время решения задач.

Работа выполнена при поддержке проекта РФФИ № 01-01-00575 и гранта Президента РФ по поддержке ведущих научных школ НШ № 1721.2003.1 "Алгебраические и логические методы в задачах распознавания и прогнозирования".

Литература

1. Дюкова Е.В. Об асимптотически оптимальном алгоритме построения тупиковых тестов для бинарных таблиц // Пробл. кибернетики. М.: Наука, 1978, Вып. 34. С. 169-187.

2. Константинов Р.М., Королева З.Е., Кудрявцев В.Б. О комбинаторно-логическом подходе к задачам прогноза рудоносности // Пробл. кибернетики. М.: Наука, 1975. Вып. 30. С. 5-33.
3. Дюкова Е.В. Сложность реализации дискретных процедур распознавания // Труды межд. Конф. "РОАИ-6-2002", Великий Новгород, 2002. Т. 1. С. 203-208.
4. Дюкова Е.В., Инякин А.С. О процедурах классификации, основанных на построении покрытий классов // Ж. вычисл. матем. и матем. физ. 2003. № 11.(принята в печать).
5. Дюкова Е.В., Инякин А.С. Задача таксономии и тупиковые покрытия целочисленной матрицы // Сообщения по прикладной математике. М.: ВЦ РАН, 2001. 28с.

Анализ и идентификация функций, заданных на сфере

А.В. Дергузов, С.А. Махортых

(Пушино)

Обобщенный спектрально-аналитический метод

Спектральный подход к обработке информационных массивов эффективен в ряде приложений, связанных с реализацией быстрых алгоритмов классификации и распознавания сигналов в классе с использованием прецедентной информации [1]. Это обстоятельство определяется возможностью перехода в пространство признаков малой размерности. Выбор информативных признаков осуществляется на этапе обучения алгоритма и основан на адаптации системы аппроксимирующих функций и оценки изменчивости признаков в классе изучаемых объектов. При этом достигается естественное обобщение классического метода Фурье на более широкий набор функциональных базисов.

В работе предлагаются методы для описания функций, заданных на сфере. Естественным базисом при этом является набор сферических гармоник [2]:

$$F_N(\theta, \lambda) = \sum_{n=0}^N \sum_{m=0}^n (A_{nm} \cos m\lambda + B_{nm} \sin m\lambda) P_{nm}(\cos \theta),$$

обладающих свойством ортогональности вида

$$\int_{-1}^1 P_{nm}(t) P_{kl}(t) dt = \frac{(n+m)! \delta_{nk} \delta_{ml}}{(n-m)! (2n+1)}$$

при $m \neq 0$.

Определение размерности признакового пространства осуществляется выбором величины N . Приводится алгоритм динамической настройки

глубины разложения по результатам выполнения промежуточной классификации. Наличие простой аналитической связи между коэффициентами разложения при применении к аргументу функции группы преобразований $SO(3)$ [3] позволяет построить быструю процедуру перебора функций в заданном классе.

Приложения. Магнитная энцефалография

Магнитная энцефалография – быстро развивающаяся в последнее время область экспериментального изучения функциональных областей мозга [4]. Сложности использования этих подходов до последнего времени были связаны со слабостью как спонтанных, так и вызванных магнитных полей, возбуждаемых токовыми источниками в мозге. Соответственно чрезвычайно высокие требования предъявлялись к измерительной аппаратуре. Магнитное поле в сравнении с электрическим испытывает значительно меньшие искажения на внутричерепных неоднородностях и покрывающих тканях, что существенно повышает точность локализации источников и снижает требования к знанию структуры внутричерепной среды. Используемые в настоящей работе данные получены с помощью 148-канального измерительного стенда со сверхпроводящими индуктивными катушками (СКВИДами) в Медицинской школе Нью-Йоркского университета.

Основной целью работы является локализация источников патологического сигнала, связанного с рядом распространенных заболеваний (болезни Паркинсона и ее разновидностей). Измеряемый сигнал представляет собой пространственно-временную структуру: 148-мерный вектор измерений в 148 точках на поверхности головы, развернутый во временной ряд с частотой опроса датчиков 500 Гц. В докладе внимание будет уделяться пространственным срезам в массивах записей, т.е. исходными данными для аппроксимации являются 148 значений потока магнитной индукции в 148-ми точках в фиксированный момент времени. При этом задача классификации получаемых паттернов поля и связанных с ними источников внутри черепной коробки будет сводиться к различению ситуаций, когда распределения источников не связаны поворотом относительно выбранного начала координат и наоборот две картины поля будут считаться совпадающими, если одну из другой можно получить поворотом сферы. Задача в такой постановке кажется тривиальной, однако, в реальности это не так. Прежде всего, это связано с неполнотой данных – датчики покрывают не всю поверхность сферы, охватывающей голову, а всего лишь примерно 1/3. Это приводит к тому, что визуально картина распределения поля может существенно измениться при повороте. Для решения задачи сравнения двух распределений с неизбежностью возникает необходимость процедуры экстраполяции данных. В излагаемом здесь подходе эта процедура естественным образом реализуется.

Приложения. *Drug design*

Следующей задачей явилось применения данных методов в задачах разработки новых лекарственных препаратов. Постановка задачи заключается в поиске в базе данных глобулярных молекул идентичных по форме и размеру заданной или группе заданных молекул. Был построен алгоритм поиска таких молекул так же с использованием разложения функции радиус-вектора поверхности молекул по сферическим функциям и получения сферических гармоник. На основании глубины разложения и коэффициентов разложения и применения операторов поворота в трехмерном евклидовом пространстве делается суждение о принадлежности молекул той или иной группе молекул.

Тестирование и результаты

Процедура распознавания объекта по прецедентной информации использует в качестве признаков коэффициенты разложения по сферическим гармоникам. При этом имеет место естественное разбиение набора признаков на группы, каждая из которых используется на соответствующем шаге процедуры. Очевидно, что подобный подход приведет к существенному ускорению вычислений, если большинство объектов в изучаемой выборке не соответствует эталону. В этом случае «отбраковка» объекта будет производиться на первых шагах, когда размерность признакового пространства минимальна (Табл.1).

Таблица 1. Процедура классификации.

Номер шага	Объект	Эталон	Результат	Результат
1	$A_{00} =$ (масштаб)	V_{00}	Да Шаг 2 	Нет Выход 
2	$\{A_{00}, A_{10}, A_{11}\} =$ (форма)	$\{V_{00}, V_{10}, V_{11}\}$	Да Шаг 3 	Нет Выход 
....

В докладе будут приведены результаты применения данной процедуры к описанным выше реальным и некоторым модельным данным.

Проводимые исследования выполняются при финансовой поддержке РФФИ (проекты 01-02-16127, 01-07-90317, 00-01-05000), проекта 107 6-го конкурса молодых ученых РАН.

Литература

1. Ф.Ф.Дедус, С.А.Махортых, М.Н.Устинин, А.Ф.Дедус. Обобщенный

- спектрально-аналитический метод обработки информационных массивов. М.: Машиностроение, 1999.
2. Г. Джеффрис, Б. Свирлс. Методы математической физики. Выпуск 3. М.: Мир, 1970.
 3. Н.Я. Виленкин. Специальные функции и теория представлений групп. М.: Наука, 1991.
 4. М.Н. Устинин, С. А. Махортых, А.М. Молчанов, М. М. Ольшевец, А. Н. Панкратов, Н.М. Панкратова, В. И. Сухарев, В.В. Сычев. Задачи анализа данных магнитной энцефалографии. В кн. Компьютеры и суперкомпьютеры в биологии. М.: Институт компьютерных технологий, 2002. С.327-349.

Об одном подходе к оптимизации АВО

А.А. Докукин

(Москва)

Введение

В данной работе рассматривается задача поиска оптимального в некотором смысле алгоритма для стандартной задачи распознавания. В качестве параметрической модели семейства алгоритмов рассматривается модель АВО (Алгоритмов Вычисления Оценок). С подробным их определением можно познакомиться в работах [1][2]. Там же (см. [2]) было показано, что в алгебраическом замыкании семейства АВО существует корректный алгоритм, т.е. алгоритм не делающий ошибок на контрольной выборке. Однако, строимый при доказательстве корректный полином, имеет высокую сложность, поскольку задачи его оптимизации не ставилось. Для минимизации степени корректного полинома требуется решить некоторую вспомогательную задачу, а именно, при некоторых дополнительных ограничениях найти АВО максимальной высоты (см. [3]). Под высотой АВО мы будем понимать разность между минимальной оценкой правильной пары (объект, класс), т.е. пары, объект которой принадлежит соответствующему классу, и максимальной оценкой неправильной пары.

Эта задача была решена для подкласса АВО со свободными весами объектов и порогами функции близости. Дальнейшее изложение посвящено описанию этого результата.

Полученный АВО, может быть в дальнейшем использован для построения корректного алгоритма, например в рамках индуктивной процедуры, описанной в [4].

γ, ε -оптимизация

Сначала опишем класс АВО $B_{\varepsilon, \gamma}$, с которым мы будем работать далее. Как уже говорилось выше, все параметры фиксированы, кроме весов

объектов обучающей выборки и порогов функции близости. Рассматривается семейство с одним опорным множеством, без ограничения общности предполагается, что это множество – все множество признаков.

Обозначим совокупность правильных пар через M_1 , а неправильных, соответственно, через M_0 . Пусть имеется правильная пара (i,j) , тогда описанная в введении задача, сводится к нахождению величины γ^* , такой что:

$$\max_{B \in \{B\}_{\gamma, \varepsilon}} \min_{(u,v) \in M_0} (\Gamma_j(S^i) - \Gamma_v(S^u)) = \min_{(u,v) \in M_0} (\Gamma_j(S^i) - \Gamma_v(S^u)) \Big|_{\tilde{\gamma} = \tilde{\gamma}^*}.$$

Алгоритм решения этой задачи состоит из двух частей: построения конечной вспомогательной системы гиперпараллелепипедов и поиску оптимального значения в этом множестве.

Вспомогательные параллелепипеды строятся следующим образом:

1. Сначала строится новая система объектов. Для каждой пары контрольный объект, обучающий объект в это множество добавляется их почленная разность. Построенное таким образом новое множество объектов разделяется на два класса – правильных и неправильных, в зависимости от правильности пары (контрольный объект, класс соответствующего обучающего объекта). Если два объекта разных классов совпадают, то считается, что в этой точке находится один неправильный объект.
2. В этой новой системе находятся все минимальные параллелепипеды, симметричные относительно нового начала координат, и содержащие различные комбинации правильных объектов и только их. Под минимальным понимается параллелепипед, являющийся пересечением всех параллелепипедов, содержащих такую комбинацию.

Для построения такой системы требуется рассмотреть различные подмножества правильных объектов из новой системы и для каждой определить, возможна ли такая комбинация, т.е. существует ли параллелепипед вида $E = [-\varepsilon_1, \varepsilon_1] \times \dots \times [-\varepsilon_n, \varepsilon_n]$, содержащий только эти объекты. При этом надо учесть, что если комбинация оказалась невозможной, то и все комбинации, содержащие ее, также невозможны. Таким образом, не требуется проводить полный перебор.

Можно доказать следующую теорему:

Теорема 1.

$$\max_{\varepsilon \in [0, \infty)^n} \min_{(u,v) \in M_0} (\Gamma_j(S^i) - \Gamma_v(S^u)) = \max_{\varepsilon \in P} \min_{(u,v) \in M_0} (\Gamma_j(S^i) - \Gamma_v(S^u))$$

Действительно, для любой окрестности $E = [-\varepsilon_1, \varepsilon_1] \times \dots \times [-\varepsilon_n, \varepsilon_n]$, максимальный параллелепипед из построенного семейства, содержащийся в ней, даст не меньшую оценку, в силу свойств АВО.

Вторая часть заключается в переборе построенной вспомогательной системы и вычисления высоты для каждого. В силу построения,

$$\Gamma_j(S^i) = x_1 \Gamma_j^1(S^i) + x_0 \Gamma_j^0(S^i) = \Gamma_j^1(S^i) + 0 \text{ и}$$

$$\Gamma_j^1(S^i) = \frac{1}{Q_1} \sum_{S \in \tilde{K}_j} \sum_{\omega \in \Omega_A} \gamma(S^i) p(\omega) B(\omega S^i, \omega S).$$

Отсюда, в свою очередь, имеем, что

$$\Gamma_j(S^i) = g_1 \gamma_1 + \dots + g_n \gamma_n, g_k \in \{0, 1\}, k = 1, \dots, n,$$

$$\Gamma_v(S^u) = g_1^{u,v} \gamma_1 + \dots + g_n^{u,v} \gamma_n, g_s^{u,v} \in \{0, 1\}, s = 1, \dots, n.$$

Откуда легко получается второй результат:

Теорема 2. Оптимальное решение имеет вид

$$\tilde{\gamma}^* : \gamma_s^* = \begin{cases} 1, & g_s = 1 \\ 0, & \text{иначе} \end{cases}, s = 1, \dots, n.$$

Действительно, для любого другого значения параметров, разница будет меньше.

Таким образом, показано, что для поиска оптимального оператора полный перебор всего континуума операторов $B_{\varepsilon, \gamma}$ можно свести к перебору конечной вспомогательной системы, причем для каждого параллелепипеда требуется найти значение линейного функционала простого вида.

Тем не менее, необходимо отметить, что сама процедура построения вспомогательной системы параллелепипедов сопряжена со значительными вычислительными сложностями, которые пока не удалось сократить без потери оптимальности решения в общем случае. Автор собирается посвятить этому вопросу дальнейшие исследования.

Работа выполнена при поддержке грантов РФФИ №№ 03-07-06141, 02-01-00558, 02-07-90134, 02-07-90137, а также проектов INTAS 00-650 и 00-370.

Литература

1. Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики. 33, М: Наука, 1978.

2. Журавлев Ю.И. Корректные алгебры над множеством некорректных (эвристических) алгоритмов // Кибернетика. 1977. 4.
3. Журавлев Ю.И., Исаев И.В. // Построение алгоритмов распознавания, корректных для заданной контрольной выборки // Ж. Выч. Мат. Мат. Физ. 1979, Т.19, №3.
4. Докукин А.А. Индуктивный метод построения корректного алгоритма в алгебрах над моделью вычисления оценок // Ж. Выч. Мат. Мат. Физ. 2003, Т.43, №8, с. 1311-1315.

Алгоритмы синтеза r -редуцированного эмпирического леса

В.И. Донской, Ю.Ю. Дюличева

(Симферополь)

Бинарные решающие деревья (БРД) широко используются при построении информационных интеллектуализированных систем и применяются для распознавания, формирования понятий, построения логических описаний закономерностей. В процессе обучения БРД возникают проблемы перенастройки (излишне точной подгонки под заданную для обучения выборку). Перенастройка «улавливает» скорее «шум» в данных, чем закономерность. Поэтому необходимо разработать критерии «отсечения» или редукции ветвей и способы использования редуцированных БРД с применением корректирующих методов, незначительно увеличивающих сложность скорректированной модели принятия решений. Последнее связано с оценкой VCD класса рассматриваемых решающих правил (РП) и решением вопроса о том, *насколько усложняется класс РП при переходе от отдельных БРД к решающему лесу.*

Конечное множество БРД с не более чем μ листьями и соответствующий этому множеству класс булевых функций обозначим $BDT(\mu, n)$. При любом $\mu = const$ получена оценка $VCD(BDT(\mu, n)) = \Theta(\log n)$.

Определим алгоритм построения r -редуцированного эмпирического леса, называемый далее DFBSA - Decision Forest Building Sequencing Algorithm.

1. Для построения леса используется эмпирическая (обучающая) непротиворечивая таблица $T_{m,n}$, содержащая m булевых наборов значений n переменных с указанной принадлежностью одному из двух классов.

2. По заданному $\varepsilon > 0$ и значениям m, n находится такой допустимый ранг r конъюнктивной закономерности, что вероятность случайного обнаружения закономерности ранга r в случайно выбранной таблице не превысит ε [1,2].

3. Строится БРД (одним из известных методов) с учетом следующего правила отсечения. Если при достройке БРД ранг ветви оказывается больше r , то в этой ветви остается r внутренних вершин, а листья, исходящие из последней по порядку вершины ветви, помечаются следующим образом. Если какой-нибудь лист из указанных двух листьев соответствует интервалу B^n , в который попадают наборы только одного класса из $T_{m,n}$, то этот лист помечается соответствующей меткой класса. Иначе лист помечается указателем (ссылкой) на корневую вершину следующего дерева, которое предстоит построить. Такое правило отсечения приводит к получению БРД, листья которого помечены либо метками классов, либо ссылками на следующее дерево.

4. Пусть уже построено $k \geq 1$ деревьев. Используемые при построении деревьев переменные (признаки) заносятся в список, называемый далее *USED*. Синтез завершается, если k -ое БРД не содержит ссылок в листьях (а содержит только указатели классов), или, в противном случае, если $k = q$, где константа q задает ограничение на возможное число деревьев эмпирического леса, либо уже были использованы все переменные. Получается либо корректный (не делающий ошибок на объектах таблицы $T_{m,n}$), либо некорректный лес. Если условие прекращения синтеза не выполняется, то начинается синтез следующего дерева. Выделяются все наборы таблицы $T_{m,n}$, которые «попали» в интервалы, соответствующие ветвям, заканчивающимися листьями со ссылками от последнего построенного дерева. Эти наборы составляют некоторую подтаблицу $T_{l,m} \subset T_{m,n}$, $l < m$. Строится следующее дерево с использованием таблицы $T_{l,m}$ с учетом нового порядка отбора переменных для внутренних вершин. Сначала используются переменные, не вошедшие в список *USED*, упорядоченные по используемому критерию выбора. Если их не хватает для синтеза ветвей допустимого ранга, используются переменные списка *USED*. Затем, после завершения построения дерева снова проверяется условие прекращения синтеза.

DFBSA последовательно строит не более q эмпирических деревьев не более чем с $\mu \leq 2^r$ листьями. В итоге получается не более чем $q \cdot 2^r$ решающих ветвей (конъюнкций).

Алгоритм принятия решений на основе построенного эмпирического леса, называемый далее **DMFSA** (*Decision Making Forest Sequencing Algorithm*) состоит в следующем. Предоставляется описание объекта – набор n булевых признаков. Указатель устанавливается на первое дерево.

Согласно значениям признаков осуществляется «прохождение» ветви и определение соответствующего листа. Если этот лист помечен номером класса – объект опознан. Иначе, если это ссылка, указатель устанавливается на следующее (определенное порядком синтеза при выполнении алгоритма **DFBSA**) дерева. Если в итоге будет получена терминальная ссылка без номера класса – принимается решение об отказе опознавания предъявленного объекта.

Результат работы алгоритма **DMFSA** определяется построенным лесом и предопределенным порядком просмотра деревьев леса. Переход на новое дерево соответствует классификации заново, по измененной системе признаков, другой ветвью. Предыдущий отказ от решения и ссылка на следующее дерево никакого значения для последующей классификации не имеет. Используемые конъюнкции остаются r – редуцированными.

Обозначим $DNF(n, \mu, r)$ класс РП, образованных ДНФ, содержащими не более μ конъюнкций ранга не более r , состоящими из литералов n переменных. Для этого класса получены следующие оценки:

$$\frac{\left(\left(\frac{2n-1}{r} \right)^r - \mu \right)^\mu}{\mu!} < |DNF(n, \mu, r)| < \frac{1.5^\mu n^{r\mu}}{\mu!},$$

$$|DNF(n, \mu, r)| = \Theta(n^{r\mu}),$$

$$VCD(DNF(n, \mu, r)) < r\mu \log n - \mu \log \frac{\mu}{2} = O(\log n),$$

$$VCD(DNF(n, \mu, r)) = \Theta(\log n).$$

Для рассматриваемого далее класса $BDF(n, \mu, r, q)$ РП, образованных решающими лесами, содержащими не более q деревьев, получены следующие оценки:

$$\max(\mu q, \log n) < VCD(BDF(n, \mu, r, q)) < r\mu q \log n - \mu q \log \frac{\mu q}{2},$$

$$VCD(BDF(n, \mu, r, q)) = \Theta(\log n).$$

Переход от БРД к r - редуцированному эмпирическому лесу не изменяет порядка VCD и существенно не увеличивает сложность расширенного класса РП. В то же время обеспечивается коррекция, позволяющая настроиться по обучающей выборке на правильную классификацию как можно большего числа объектов. Такая возможность объясняется прежде всего тем, что эмпирический лес может использовать различные подсистемы признаков

для синтеза отдельных деревьев, не увеличивая при этом рангов решающих конъюнкций.

Литература

1. Донской В.И., Дюличева Ю.Ю. Индуктивная модель g -корректного эмпирического леса// Труды международной конференции по индуктивному моделированию: Львов, 2002. С.54-58.
2. Дюличева Ю. Ю. Принятие решений на основе индуктивной модели эмпирического леса//Искусственный интеллект, 2002, №2, с. 110-115.

Методы классификационного анализа данных в задаче структурного прогнозирования динамических объектов

А.А. Дорофеюк

(Москва)

Поставлена задача многомерного структурного прогнозирования как одна из задач многомерного классификационного анализа. Идея этой постановки состоит в следующем. Пусть имеется N объектов, каждый из которых характеризуется набором из k параметров. Изучается поведение объектов во времени, то есть в некоторые моменты времени (например, с заданной периодичностью) производится измерение всех параметров-характеристик для всех объектов. Вводится в рассмотрение k -мерное пространство параметров X , в котором j -ый объект в каждый конкретный момент времени t представляется точкой $x_j(t)$. Упорядоченная совокупность точек $x_j(t_1), \dots, x_j(t_n)$, соответствующая последовательности моментов времени t_1, t_2, \dots, t_n , в которых производится измерение соответствующих параметров, является известной частью траектории j -го объекта. В большинстве постановок задач прогнозирования требуется предсказать по известной части траектории положение следующей на ней точки $x_j(t+1)$ (то есть значения параметров для этого объекта в момент времени t_{n+1}). Однако для многих прикладных задач требуется несколько другое прогнозирование. А именно, требуется прогнозировать не точные значения параметров, а лишь характер или тип поведения объекта в рамках изучаемого множества объектов в момент времени t_{n+1} . Для формализации этого понятия предложено использовать методологию классификационного анализа данных [1]. С этой целью в момент времени t_1 производится автоматическая классификация (кластеризация) N точек в пространстве X на небольшое (3-5) число классов r , каждый из которых и характеризует тип объекта (в пределах изучаемого множества объектов). Моделью каждого класса является точка «центра тяжести» (центра) этого класса. Для каждой точки помимо принадлежности к конкретному классу вычисляются также

расстояния (или близости) до центров всех классов. Для данной постановки более адекватным является использование алгоритмов размытой классификации, поскольку в этом случае значения функций принадлежности конкретного объекта к каждому классу являются аналогами этих расстояний.

Вопрос содержательной интерпретации полученных классов (типов) решается экспертными методами и выходит за рамки поставленной задачи. В момент времени t_2 каждая точка относится к тому или иному классу с помощью одного из алгоритмов распознавания образов с учителем. В настоящей работе использовался алгоритм метода потенциальных функций, который в спрямляющем пространстве эквивалентен алгоритму ближайшего среднего [2]. После того, как определена принадлежность всех точек к тому или иному классу, производится пересчет центров всех классов (фактически, это эквивалентно проведению классификации $2N$ точек). Для каждой точки с предыдущего шага пересчитываются, а для каждой новой точки вычисляются значения функций принадлежности ко всем классам (расстояния до центров классов). Такая процедура выполняется для всех n моментов времени. В итоге для каждого объекта получается последовательность (траектория) из n позиций. В каждой позиции находится $r+1$ число, первое из которых – это номер класса, к которому относился этот объект в соответствующий момент времени, а последующие числа – это значения функций принадлежности (расстояния до центров классов) в тот же момент времени. Требуется спрогнозировать номер класса (тип объекта), к которому будет относиться каждый объект в момент времени t_{n+1} .

В качестве прогнозной модели для каждого объекта используется марковская цепь с r состояниями. Разработан специальный алгоритм пересчета на каждом шаге соответствующих переходных вероятностей с использованием информации о значениях функций принадлежности (расстояний до центров классов). Рассмотрена модификация процедуры прогнозирования, когда типология объектов задается заранее, например, экспертным способом и в последующем остается неизменной.

Литература

1. Бауман Е.В., Дорофеев А.А. Классификационный анализ данных // В сб.: “Избранные труды Международной конференции по проблемам управления. Том 1”. М.: СИНТЕГ, 1999, С. 62-67.
2. Айзерман М.А., Браверман Э.М., Розоноэр Л.И. Метод потенциальных функций в теории обучения машин // М.: Наука, 1970.

Классификационные методы анализа сложноорганизованных данных

А.А. Дорофеев, Е.В. Бауман

(Москва)

Разработана теория, математические методы и алгоритмы выявления структуры и анализа сложноорганизованных данных. Был разработан общий вариационный подход к решению задач классификационного анализа данных [1]. Данный подход был распространён на задачи построения качественной размытой классификации, упорядоченной размытой классификации; был обобщен на случай анализа информации, заданной в виде матрицы развивающейся во времени; дополнен методом построения классификации с фиксированным классом решающих правил и методами построения размытой классификации и аппроксимации, позволяющими находить глобальные экстремумы выбранного критерия качества. Были также разработаны и исследованы методы сравнения размытых классификаций, группировки классификаций, а также сравнения и группировки параметров, измеренных в разных шкалах (номинальных, ранговых, количественных).

Рассмотрены вопросы теоретического анализа и построения алгоритмов для широкого класса задач классификационного анализа, различных критериев качества и различных вариантов размытости. Выделены три основные задачи классификационного анализа данных:

первая: классификация объектов по заданному набору параметров;

вторая: структуризация заданного набора параметров;

третья: аппроксимация зависимости выходных показателей от входных.

Общий подход позволяет единообразно решать эти задачи. Он формулируется при помощи трех основных категорий: классифицируемое множество объектов, класс допустимых классификаций и функционал качества разбиения.

Классифицируемое множество объектов – конечное или бесконечное множество X k -мерных объектов x .

Класс допустимых классификаций - размытые классификации множества X на g классов, задаваемые g -мерной вектор-функцией $H(x) = \{h_1(x), \dots, h_r(x)\}$, $h_i(x)$ - функция принадлежности x к i -му классу,

$0 \leq h_i(x) \leq 1$, $\sum_{i=1}^r h_i(x) = 1$, т.е. вектор-функция $H(x)$ принимает значения в g -

мерном единичном симплексе. Для каждой конкретной задачи классификационного анализа вводятся дополнительные ограничения на $H(x)$. Считается, что для любого x значение $H(x)$ принадлежит некоторому подмножеству V единичного симплекса, которое определяет тип размытости для данной задачи классификации.

Критерий качества классификации. Считается, что объекты i -го класса искомой классификации должны хорошо описываться некоторой моделью (эталоном) класса α_i . В соответствии с этим вводится в рассмотрение множество возможных эталонов классов A . Между элементами множества объектов X и элементами множества эталонов A вводится некоторая мера близости $K(x, a)$. Обычно за критерий качества классификации берётся

функционал
$$J = \sum_{i=1}^r \sum_{t=1}^n K(x_t, a_i) \varphi(h_i(x_t)).$$
 Было показано, как за счет

выбора функции $\varphi(h)$ и множества V можно получить четкую классификацию, размытую классификацию, классификацию с размытыми границами.

Была формально поставлена задача качественной размытой классификации, для чего вводятся уровни принадлежности объекта каждому из классов. В такой постановке упрощает интерпретацию результатов, особенно при анализе динамических объектов. Другим вариантом качественной размытой классификации является классификация с пересекающимися классами, когда объект может либо принадлежать однозначно одному классу, либо с одинаковыми весами нескольким классам одновременно. Для обоих случаев были построены соответствующие функции $\varphi(h)$ и множества V , разработаны алгоритмы нахождения оптимальных классификаций и исследована их сходимость [2].

Центральным понятием при решении задачи классификационного анализа является понятие эталонной классификации [1]. Пусть зафиксированы эталоны классов. Эталонной является классификация, оптимизирующая выбранный критерий при этом наборе эталонов.

Рассмотрен вариант задачи классификационного анализа, когда рассматривается два множества эталонов A и B и, соответственно, две функции близости $K(x, a)$ и $L(x, b)$. Рассмотрим множество всех эталонных классификаций $D(B)$, построенных по наборам эталонов из множества B . Задача состоит в оптимизации критерия качества классификации, определенного с помощью множества A , не по всему множеству возможных классификаций, а лишь по множеству $D(B)$. Такая задача называется задачей **классификации с фиксированным классом решающих правил**.

Наиболее интересным примером использования задачи классификации с фиксированным классом решающих правил является построение кусочной аппроксимации [3].

Особенностью разработанных алгоритмов является то, что они находят локальные экстремумы соответствующих критериев. Это приводит к сильной зависимости результатов работы алгоритмов от начальных условий.

В работе рассматриваются подходы к нахождению глобальных

экстремумов критерия качества для некоторых задач классификационного анализа данных, а именно:

- алгоритм классификации для конечного множества эталонов;
- одномерная классификация методом динамического программирования;
- одномерная классификация методом динамического программирования с фиксированным классом решающих правил;
- одномерная кусочно-линейная аппроксимации методом динамического программирования.

Разработан метод структуризации результатов классификационного анализа, основанный на двух мерах связи размытых классификаций [4]. Первая из них основана на сравнении размытых классов по Заде, вторая - на предположении о вероятностной зависимости между классами. Эти меры адаптированы для случая размытой упорядоченной классификации.

На основе предложенных мер близости разработаны методы группировки множества размытых классификаций (размытых номинальных признаков). Это дает возможность структурировать множество результатов работы алгоритмов классификации, а также структурировать множество параметров, измеренных в разных шкалах: количественных, номинальных и ранговых, причем последние могут быть даны в размытом варианте.

Разработанные методы опробованы на модельном материале и при решении ряда прикладных задач (оптимизация налоговых ставок, совершенствование системы управления региональным здравоохранением, совершенствование системы управления пассажирскими автоперевозками и ряда других). Результаты моделирования подтвердили высокую эффективность разработанных методов.

Литература

1. Бауман Е.В., Дорофеюк А.А. Классификационный анализ данных //В сб.: "Избранные труды Международной конференции по проблемам управления. Том 1". М.: СИНТЕГ, 1999.
2. Бауман Е.В., Зубчевский Н.С. Задача качественной размытой классификации //Вторая международная конференция по проблемам управления. Тезисы докладов, том 1, М.: ИПУ РАН, 2003, С. 144.
3. Бауман Е.В., Дорофеюк А.А., Корнилов Г.В. Алгоритмы оптимальной кусочно-линейной аппроксимации сложных зависимостей //Вторая международная конференция по проблемам управления. Тезисы докладов, том 1, М.: ИПУ РАН, 2003, С. 141-143.
4. Бауман Е.В., Москаленко Н.Е. Меры связи для сравнения размытых классификаций //Вторая международная конференция по проблемам управления. Тезисы докладов, том 1, М.: ИПУ РАН, 2003, С. 145.

Решение задач распознавания логическими алгоритмами, ориентированными на бинарную информацию

А.Г. Дьяконов
(Москва)

В докладе рассматривается задача распознавания с целочисленными признаками. Для решения этой задачи очень часто используются логические алгоритмы распознавания [1]. Их применение основано на синтезе множества элементарных классификаторов (фрагментов подписаний, содержащих информацию о различиях классов). Задачу построения множества элементарных классификаторов можно формально записать как задачу синтеза ДНФ характеристических функций классов (функции заданы только на описаниях эталонных объектов). В k -значной логике понятие "нормальная форма" может быть введено по-разному (см. [2,3]). В предыдущих работах рассматривались отдельные обобщения понятия ДНФ, и в соответствии с ними выбирались элементарные классификаторы. Как правило, способ обобщения определялся требованиями, накладываемыми на элементарные классификаторы.

В настоящем докладе предлагается рассматриваемую задачу распознавания сводить к задаче с бинарными признаками. Такое сведение производится кодировкой каждого значения признака булевым вектором, а новая задача решается стандартными методами (построение ДНФ частично заданной булевой функции). Полученная ДНФ легко перекодируется в нормальную форму k -значной логики (или сразу во множество элементарных классификаторов исходной задачи). Оказывается, что в зависимости от способа кодировки можно получать нормальные формы специальных видов. При этом в наиболее интересных случаях искомые элементарные классификаторы автоматически выписываются по ДНФ булевой функции.

Рассматривается также задача синтеза ДНФ по перечню нулей. Разработаны эффективные алгоритмы решения этой задачи, ориентированные на применение в распознавании образов.

Предложенные методы применялись на практике при решении задач классификации. При этом рассматривались также вещественные признаки, которые кодировались в целочисленные по некоторым эвристическим правилам.

Работа выполнена при финансовой поддержке РФФИ (проект 02-01-00558) и Минпромнауки (грант "Ведущие научные школы" НШ-1721.2003.1).

Литература

1. Дюкова Е.В., Журавлёв Ю.И. Дискретный анализ признаков описаний в задачах распознавания большой размерности // Ж. вычисл. матем. и матем. физ. 2000. Т. 40. № 8. С. 1264–1278.

2. Абдугалиев У.А. О нормальных формах k -значной логики // Кибернетика. 1967. №1. С. 16–20.
3. Нурлыбаев А.Н. О нормальных формах k -значной логики // Сборник работ по математической кибернетике. М.: ВЦ АН СССР, 1976. Вып. 1. С. 56-68.

Асимптотика логарифма числа тупиковых σ -покрытий целочисленной матрицы

Е.В. Дюкова, А.Б. Пьянов

(Москва)

В докладе изучаются метрические (количественные) свойства множества покрытий целочисленной матрицы. Получена асимптотика логарифма типичного числа тупиковых σ -покрытий целочисленной матрицы для случая, когда число строк в матрице не меньше числа столбцов.

Актуальность задачи следует из необходимости построения эффективных реализаций для дискретных (логических) процедур распознавания, требующих больших вычислительных затрат. Близкими задачами являются задачи оценки числа максимальных конъюнкций логических функций.

Пусть L – целочисленная матрица размера $m \times n$ с элементами из множества $\{0, 1, \dots, k-1\}$, $k \geq 2$. Будем рассматривать наборы вида $\sigma = (\sigma_1, \dots, \sigma_r)$, где $\sigma_i \in \{0, 1, \dots, k-1\}$. Напомним [1,2], что σ -покрытием целочисленной матрицы L называется набор столбцов H этой матрицы, для которого выполнено следующее условие: подматрица L^H матрицы L , образованная столбцами набора H , не содержит строку σ . Тупиковым σ -покрытием целочисленной матрицы L называется набор столбцов H , являющийся покрытием и такой, что L^H содержит (с точностью до перестановки строк) подматрицу вида

$$\begin{bmatrix} \beta_1 & \sigma_2 & \sigma_3 & \dots & \sigma_{r-1} & \sigma_r \\ \sigma_1 & \beta_2 & \sigma_3 & \dots & \sigma_{r-1} & \sigma_r \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \sigma_1 & \sigma_2 & \sigma_3 & \dots & \sigma_{r-1} & \beta_r \end{bmatrix},$$

где $\beta_p \neq \sigma_p$ для $p = 1, 2, \dots, r$. Такая подматрица называется σ -подматрицей.

Понятие тупикового $(0, \dots, 0)$ -покрытия булевой матрицы совпадает с

хорошо известным понятием неприводимого покрытия булевой матрицы. Отметим, что $(0, \dots, 0)$ -подматрица булевой матрицы является единичной подматрицей.

Пусть M_{mn}^k - множество всех матриц размера $m \times n$ с элементами $\{0, 1, \dots, k-1\}$, $k \geq 2$; E_k^r , $k \geq 2$, $r \leq n$, - множество всех наборов вида $(\sigma_1, \dots, \sigma_r)$, где $\sigma_i \in \{0, 1, \dots, k-1\}$.

Пусть $L \in M_{mn}^k$, $\sigma \in E_k^r$. Положим

$C(L, \sigma)$ - множество всех σ -покрытий матрицы L ,

$S(L, \sigma)$ - множество всех σ -подматриц матрицы L ,

$B(L, \sigma)$ - множество всех тупиковых σ -покрытий матрицы L ,

$$C(L) = \bigcup_{r=1}^n \bigcup_{\sigma \in E_k^r} C(L, \sigma), \quad S(L) = \bigcup_{r=1}^n \bigcup_{\sigma \in E_k^r} S(L, \sigma),$$

$$B(L) = \bigcup_{r=1}^n \bigcup_{\sigma \in E_k^r} B(L, \sigma),$$

$|A|$ - мощность множества A .

В [1,2] показано, что асимптотика величины $|B(L)|$ совпадает с асимптотикой величины $|S(L)|$ для почти всех матриц из M_{mn}^k при условиях $n \rightarrow \infty$ и $m^\alpha \leq n \leq k^{m^\beta}$, $\alpha > 1$, $\beta < 1$. На основе этого факта построен асимптотически оптимальный алгоритм поиска тупиковых покрытий. Показано также, что в данном случае число покрытий из $B(L)$ почти всегда по порядку меньше числа покрытий из $C(L)$.

В [3] рассмотрен прямо противоположный случай, а именно, когда $n^\alpha \leq m \leq k^{n^\beta}$, $\alpha > 1$, $\beta < 1$, $n \rightarrow \infty$. Получена асимптотика типичного значения числа подматриц из $S(L)$. Кроме того, для практически общего случая получена асимптотика типичного значения числа покрытий из $C(L)$. На основе сравнения найденных оценок установлено, что в случае, когда

$n^\alpha \leq m \leq k^{n^\beta}$, $\alpha > 1$, $\beta < 1/2$, почти всегда величина $|S(L)|$ по порядку при $n \rightarrow \infty$ больше величины $|B(L)|$.

В данной работе доказана

Теорема. Если $n \leq m, m+1 \leq k^{n-2}$, то для почти всех матриц L из M_{mn}^k при $n \rightarrow \infty$ верно

$$\log_k |B(L)| \approx \log_k C_n^{r_1} + r_1,$$

где $r_1 = \lceil \log_k m - \log_k \ln \log_k m \rceil - 1$.

При доказательстве теоремы использованы методы, предложенные в [4] для получения асимптотики логарифма типичного числа максимальных конъюнкций частичной булевой функции. Рассмотренная в [4] задача несколько сложнее задачи, решенной в данной работе. Поэтому используемые технические конструкции существенно упрощены.

Работа выполнена при поддержке проекта РФФИ № 01-01-00575 и гранта Президента РФ по поддержке ведущих научных школ НШ № 1721.2003.1 "Алгебраические и логические методы в задачах распознавания и прогнозирования".

Литература

1. Дюкова Е. В. О сложности реализации некоторых процедур распознавания // Ж. Вычисл. матем. и матем. физ. 1987. Т. 27, №1. С. 114-127.
2. Дюкова Е. В., Журавлев Ю.И., Дискретный анализ признаков описаний в задачах распознавания большой размерности // Ж. вычисл. матем. и матем. физ. 2000. Т. 40, № 8. С. 1264-1278.
3. Дюкова Е.В., Песков Н.В. Поиск информативных фрагментов описаний объектов в дискретных процедурах распознавания // Ж. вычисл. матем. и матем. физ. 2002. №5, Том 42. С. 743-755.
4. Сапоженко А.А., Оценка числа тупиковых д.н.ф. для почти всех не всюду определенных булевых функций // Математические заметки, 1980 № 2, т.28, с. 279-299

Сравнительный анализ монотонной и выпуклой коррекции в задачах классификации

С.В. Елисеев, К.В. Воронцов

(Москва)

В течение последних 10 лет большую популярность приобрели методы построения выпуклых комбинаций классификаторов, такие как баггинг [1] и бустинг [2], главным образом, благодаря своей простоте и неожиданно высокой эффективности.

В бустинге строится последовательность классификаторов, к которой затем применяется взвешенное голосование. Путем пересчета весов обучающих объектов каждый следующий классификатор точнее настраивается на наиболее «трудных» объектах, на которых чаще ошибались предыдущие классификаторы. Одновременно пересчитываются веса самих классификаторов. Эксперименты [3] показали, что обобщающая способность (частота правильной классификации на независимой от обучения тестовой выборке) получаемой алгоритмической композиции может практически неограниченно увеличиваться по мере наращивания числа базовых классификаторов. Более того, она продолжает увеличиваться даже после достижения безошибочного распознавания обучающей выборки. Эти феномены противоречат распространенному представлению о необходимости ограничивать сложность алгоритмов. Впоследствии они получили определенное теоретическое обоснование [4].

Выпуклая комбинация — далеко не единственный способ коррекции эвристических алгоритмов. Наиболее глубоко методы коррекции изучаются в алгебраическом подходе к построению корректных процедур обработки информации, развиваемом академиком РАН Ю. И. Журавлевым [5] и его научной школой. В частности, был разработан метод монотонной коррекции, имеющий схожую с бустингом архитектуру, но отличающийся применением монотонных функций достаточного общего вида вместо выпуклой комбинации [6]. Монотонность можно рассматривать как обобщение выпуклости: любая выпуклая корректирующая операция является монотонной, обратное в общем случае неверно. При выпуклой коррекции вес каждого базового алгоритма остается постоянным на всем пространстве объектов, что представляется не вполне обоснованной эвристикой. Монотонная коррекция обладает существенно более богатыми возможностями для настройки. С другой стороны, для монотонных корректирующих операций, как для более широкого семейства функций, существенно выше опасность переобучения.

Обобщающая способность выпуклых классификаторов достаточно хорошо исследована, чего нельзя сказать об остальных видах корректирующих операций. В данном докладе сообщаются результаты первых экспериментов по сравнительному анализу выпуклой и монотонной

коррекции. Эксперименты проводились на нескольких реальных задачах из репозитория UCI [7]. В ходе экспериментов был разработан оригинальный вариант известного алгоритма AdaBoost, сочетающий достоинства бустинга и баггинга, и названный SemaBoost. Предложенный алгоритм более устойчив при низком качестве базовых классификаторов.

Эксперименты показали, что ни один из методов коррекции не является универсально лучшим. В то же время, существует класс задач, на которых монотонная коррекция показывает лучшую обобщающую способность, чем выпуклая. Число базовых алгоритмов в монотонном корректоре как правило существенно меньше, чем в сопоставимом по качеству выпуклом. При числе базовых алгоритмов, большим 3, монотонные корректоры склонны к переобучению. Эта проблема эффективно решается путем построения сети монотонных корректоров — алгоритмической композиции, в которой каждый корректор объединяет небольшое число алгоритмов.

Работа выполнена при поддержке Российского фонда фундаментальных исследований, проекты №02-01-00325 и №01-07-90242.

Литература

1. Breiman L. Bagging Predictors // Machine Learning. — 1996. — Vol. 24, no. 2. — Pp. 123-140.
2. Freund Y., Schapire R. E. A decision-theoretic generalization of on-line learning and an application to boosting // European Conference on Computational Learning Theory. — 1995. — Pp. 23-37.
3. Freund Y., Schapire R. E. Experiments with a New Boosting Algorithm // International Conference on Machine Learning. — 1996. — Pp. 148-156.
4. Schapire R. E., Freund Y., Lee W. S., Bartlett P. Boosting the margin: a new explanation for the effectiveness of voting methods // Annals of Statistics. — 1998. — Vol. 26, no. 5. — Pp. 1651-1686.
5. Журавлёв Ю. И., Рудаков К. В. Об алгебраической коррекции процедур обработки (преобразования) информации // Проблемы прикладной математики и информатики. — 1987. — С. 187-198.
6. Рудаков К. В., Воронцов К. В. О методах оптимизации и монотонной коррекции в алгебраическом подходе к проблеме распознавания // Доклады РАН. — 1999. — Т. 367, № 3. — С. 314-317.
7. Blake C., Merz C. UCI repository of machine learning databases: Tech. rep.: Department of Information and Computer Science, University of California, Irvine, CA, 1998.

О задаче оптимального оценивания параметров объекта по его изображению

Г. С. Животников

(Москва)

Существуют измерительные устройства, основное назначение которых состоит в визуализации некоторых параметров изучаемого объекта с целью последующего анализа их исследователем. В подавляющем большинстве случаев интерпретация получаемых с их помощью изображений требует непосредственного участия человека. Как правило, результат визуализации содержит помимо информации, интересующей исследователя (информации о параметрах изучаемого объекта), также детали, которые исследователем воспринимаются как помехи. Речь идет о варьирующихся от измерения к измерению условиях регистрации объекта, влияющих на результат визуализации, а также о шуме, привнесенном самим измерительным устройством.

В докладе рассматриваются некоторые процедуры, позволяющие автоматически, без вмешательства оператора, получать выводы о параметрах исследуемого объекта по его изображению. Традиционные алгоритмы оценивания параметров объекта по его изображению, основанные на, к примеру, корреляционных методах, позволяют в некоторых случаях избавиться от негативного влияния помех, связанных с шумом измерительного устройства; однако в общем случае их нельзя сделать инвариантными по отношению к изменениям условий регистрации объекта. В докладе речь идет об алгоритмах, основанных на морфологических методах анализа изображений [1], обеспечивающих такую инвариантность в достаточно естественных предположениях.

В качестве общей черты процедур получения статистических выводов, в основе которых (процедур) лежат морфологические методы, можно указать следующую последовательность действий:

- Исследователь описывает классы изображений, соответствующих каждому из возможных значений интересующих его параметров объекта; множество этих значений может иметь как конечную мощность (как в задаче узнавания), так и мощность континуума (как в задаче оценивания). Таким образом, каждому возможному значению параметров ставится в соответствие множество изображений. Описание этих множеств, или классов, может быть формализовано а) конструктивно, т.е. с указанием изображения-эталона (для каждого из возможных значений параметров объекта) и класса преобразований изображения, моделирующих вариации условий измерения; и, в более общем случае б) с помощью необходимых и достаточных условий, которым удовлетворяют изображения объекта с данными значениями параметров.

- Исходя из этих условий для каждого класса изображений строится алгоритм, ставящий в соответствие произвольному изображению изображение из данного класса, которое является в некотором смысле “наилучшим приближением” исходного. Такой алгоритм часто представляют в виде оператора; этот оператор, очевидно, должен являться проектором.
- На основе этого алгоритма (оператора) строится решающее правило, которое уже зависит от конкретной задачи [3] (понятно, что для задач узнавания, оценивания и подавления помех вид решающих правил совершенно различен).

Пусть исследуемый объект характеризуется некоторым набором параметров, значения которых необходимо оценить. В качестве входных данных процедуры оценивания предлагается изображение объекта, содержащее информацию о значениях интересующих исследователя параметров. В дальнейшем совокупность всех параметров, интересующих исследователя и влияющих на предъявляемое для анализа изображение, будем обозначать как λ ; множество всевозможных значений параметров, соответственно, обозначим Λ .

Пусть $f_\lambda(\cdot)$ --- эталонное изображение, которое соответствует ситуации, когда $\lambda \in \Lambda$ --- значения параметров исследуемого объекта. Его формой V_λ называется множество всевозможных изображений, соответствующих одному и тому же набору параметров λ и различным условиям регистрации [2]. Оператор проецирования произвольного изображения на форму V_λ эталонного изображения $f_\lambda(\cdot)$ обозначим P_λ . Множество изображений объекта при всевозможных значениях параметров и всевозможных условиях регистрации обозначим V_Λ ; оно равно

$$V_\Lambda = \bigcup_{\lambda \in \Lambda} V_\lambda$$

и, вообще говоря (и как правило), не совпадает с пространством всех изображений $L(X)$.

Множество изображений, принадлежащих каждому из множеств V_λ , $\lambda \in \Lambda$, обозначим V_1 :

$$V_1 = \bigcap_{\lambda \in \Lambda} V_\lambda .$$

Множество V_1 состоит из изображений, на основании которых предлагаемая процедура оценивания не в состоянии сделать вывод о значении параметров исследуемого объекта.

Для дальнейшего принципиальным является выполнение еще одного условия на множества V_λ , $\lambda \in \Lambda$. А именно,

$$\forall g(\cdot) \in V_\Lambda \setminus V_1; \forall \lambda_1, \lambda_2 \in \Lambda: \|(P_{\lambda_1} - P_{\lambda_2})g(\cdot)\| \geq \alpha \|g(\cdot)\| \|\lambda_1 - \lambda_2\|,$$

где $\alpha > 0$ не зависит от конкретных λ_1, λ_2 и $g(\cdot)$, а является некоторой универсальной (для данного набора множеств $V_\lambda, \lambda \in \Lambda$) постоянной. Это условие определяет “различимость” значений параметров объектов, изображения которых предъявляются для анализа, с точки зрения предлагаемой ниже процедуры оценивания.

Рассмотрим стратегию $\lambda^*(g(\cdot)): L(X) \rightarrow \Lambda$, определенную как решение следующей задачи на минимум:

$$\|g(\cdot) - P_{\lambda^*(g(\cdot))}g(\cdot)\| = \min_{\lambda \in \Lambda} \|g(\cdot) - P_\lambda g(\cdot)\|, \quad (*)$$

где $P_\lambda: L(X) \rightarrow V_\lambda$ --- оператор проецирования на множество V_λ .

В докладе рассмотрены статистические свойства этой стратегии в сравнении с традиционными алгоритмами оценивания параметров объекта по его изображению; указаны свойства, характеризующие ее оптимальность¹.

Автор благодарит проф. Ю. П. Пытьева за поставленную задачу и обсуждение результатов.

Литература

1. Пытьев Ю. П. Морфологический анализ изображений. //ДАН СССР, 1983, т.~269, №5, сс. 1061--1064.
2. Pyt'ev Yu. P. Morphological Image Analysis. //Pattern Recognition and Image Analysis, 1993, vol. 3, no. 1, pp. 19--28.
3. Животников Г. С., Пытьев Ю. П. Теоретико-возможностные модели распознавания //Труды конференции "Математические методы распознавания образов-10", 2001 г.

Развитие алгоритмов самоорганизации по методу группового учета аргументов

А.Г. Ивахненко, А.Б. Надирадзе, Г.А. Ивахненко, Е.А. Савченко
(Киев, Москва)

Введение

Существует некоторое сходство между законами человеческого мышления и алгоритмами математического моделирования. При индуктивном моделировании подобно индуктивному мышлению, одна общая модель получается на основании обработки множества наблюдений,

¹ Критерием качества является точность: например, среднеквадратичная погрешность --- в задаче оценивания, и вероятность принятия ошибочного решения --- в задаче узнавания.

представленных в выборке данных. В так называемых интерактивных системах в выборе оптимальной модели участвует человек – автор моделирования. В таких системах действует правило: чем сложнее модель, тем она точнее. Человек, исходя из своего опыта, субъективно выбирает структуру модели. В отличие от этого в системах самоорганизации, выбор модели оптимальной сложности, соответствует минимуму специального внешнего критерия, который учитывает как ошибку, так и смещение модели. Во всех алгоритмах Метода Группового Учета Аргументов (МГУА), начиная с самых первых публикаций [1,2] для учета смещения модели, выборка данных, обязательно, делится на две части. При этом оценки коэффициентов получаются по методу наименьших квадратов (м.н.к.) на одной выборке, а структура оптимальной модели находится объективно на другой выборке. Человек в выборе оптимальной модели не участвует. Значение самоорганизации моделей с течением времени возрастает, так как сложность задач моделирования увеличивается, что приводит к увеличению числа субъективных ошибок человека. По определению, при отсутствии смещения, перемена местами выборок не меняет результат. Отсутствие смещения есть свойство всех законов физики. Например, чтобы обнаружить закон Ома, среди множества выражений-кандидатов достаточно сравнить результат их действия на двух экспериментах. По данным одного эксперимента находится значение сопротивления, а по данным другого – проверяется действие предлагаемого выражения. Аналогично этому, для получения несмещенной модели оценки определяются на одной выборке данных, а структура оценивается на другой. Для линейного закона, его соблюдение на двух наблюдениях, означает точность действия на всех других выборках. Учет смещения модели при помощи указанного внешнего критерия, можно назвать учетом смещения в неявной форме, так как смещение определенным числом не оценивается. Учет смещения модели повышает свойство обобщения модели на другие выборки, полученные на том же объекте.

Два способа решения вопроса: «где остановиться при постепенном повышении сложности моделей?»

Первичными аргументами, обычно, называют переменные, заданные в исходной выборке наблюдений, вторичными можно назвать простые функции, учитывающие два - три первичных аргумента. Чаще всего в качестве вторичных аргументов применяются парные ковариации первичных аргументов. Расширение выборки данных при помощи генерации вторичных аргументов позволяет получить по м.н.к. оценки коэффициентов сложных переборных моделей, у которых ошибка, измеренная на тестовой выборке, будет равна нулю. Это произойдет, когда с учетом свободного члена полиномиальной модели, число строк выборки будет на единицу больше числа ее столбцов, которое, в свою очередь, равно общему числу всех аргументов, как первичных, так и вторичных. Возникает вопрос, почему

имея возможность получения моделей, не имеющих ошибки, никто не применяет эти модели. Другими словами, почему и где нужно остановиться при постепенном усложнении моделей. Ответ прост, оптимальные модели должны быть точными не только на данной выборке, но и обладать свойством обобщения на все соседние выборки данных, которых еще может быть и нет в нашем распоряжении. До появления МГУА использовался, в основном, один способ выбора модели оптимальной сложности – субъективное назначение сложности модели автором моделирования. Вместе с МГУА появилась так называемая самоорганизация оптимальной модели.

Определение модели оптимальной сложности называется самоорганизацией модели, если в этом процессе не участвует человек – автор моделирования. При самоорганизации сложность моделей постепенно увеличивается до тех пор, пока не будет достигнуто минимальное значение внешнего критерия, учитывающего как ошибку, так и смещение модели.

Область применения алгоритмов самоорганизации моделей по МГУА

Алгоритмы самоорганизации моделей применяются для решения задач искусственного интеллекта интерполяционного типа. Примерами могут служить задачи обнаружения закономерностей в выборке данных, восстановления пропущенных наблюдений, идентификации текущего состояния объекта (задача диагноза), краткосрочного и долгосрочного пошагового прогноза случайных процессов. Во всех этих задачах выборка данных наблюдений может быть приведена к условной форме Гаусса, при которой в каждой строке выборки участвуют будущие, текущие и прошедшие значения выходной переменной и ее аргументов, рассматриваемые как независимые переменные. По законам алгебры, в условных выборках данных можно свободно менять местами порядок следования строк и, следовательно, разделить выборку на компактные множества, называемые кластерами. Кластеризация служит основным алгоритмом решения задач распознавания образов. Таким образом, все указанные задачи могут быть сведены к задаче распознавания образов.

Три зоны переборного процесса

Экспериментальные исследования зависимости специального внешнего критерия, учитывающего как точность, так и смещение модели, зависят от дисперсии помех, наложенных на выходную переменную. Величина помехи определяет собой зоны различных форм переборного процесса. В первой зоне, при достаточно больших помехах переборная характеристика острая, и в ее минимум попадает только одна модель. При уменьшении помех перебор переходит во вторую зону, где переборная характеристика менее острая, а в области минимума содержится несколько моделей, образующих интервал неопределенности выбора модели. Причиной образования этого интервала служит дискретный характер изменения сложности модели, так как число

аргументов модели может быть только целым числом. Наконец, если дисперсия помех уменьшается дальше, то переборная характеристика становится настолько пологой, что можно говорить о существовании зоны случайного выбора оптимальной модели.

Доопределение модели по смещению в явной форме

Чтобы преодолеть зону неопределенности выбора оптимальной модели и одновременно учесть свойство обобщения, предложено последовательно использовать два перебора. Сначала по внешнему критерию точности найти все модели, образующие интервал неопределенности, а затем, сравнивая модели, попавшие в этот интервал по критерию смещения в явной форме, выбрать из них одну оптимальную модель. Ниже приводится пример осуществления такого перебора по двум критериям, используемым по очереди. Как указывалось, учет смещения модели, как в неявной, так и в явной форме, невозможен без разделения выборки на две части. Чтобы исключить решение вопроса о том, на какие две части следует разделить имеющиеся данные, ниже описан алгоритм расчета перекрестного критерия смещения, аналогично перекрестному критерию точности.

По определению, модель является несмещенной, если все ее характеристики на двух выборках данных одни и те же. Наиболее полно свойство несмещенности выражает необходимое и достаточное условие равенства коэффициентов модели при ее получении на одной и другой выборке. Часто более удобным является условие равенства ошибок моделей, полученных таким способом. Именно равенство ошибок моделей, получаемых на двух выборках, положено в основу расчета перекрестного критерия смещения. Для несмещенности требуется чтобы ошибка модели, рассчитанная на одной строке выборки была равна средней ошибке, полученной на всех остальных строках.

Алгоритм расчета перекрестного критерия смещения

Задача состоит в том, чтобы для моделей, полученных по комбинаторному алгоритму МГУА и попавших в интервал неопределенности моделей, определить смещение с тем, чтобы выбрать наименее смещенную модель.

Алгоритм решения задачи состоит из следующих этапов:

- 1) Пользуясь всей выборкой данных, без деления ее на части, находим оценки коэффициентов модели.
- 2) Делим выборку на две части: первая содержит одну строку, а другая все остальные строки. Рассчитываем ошибку для одной строки и среднюю ошибку для всех остальных строк. Разность полученных ошибок запоминается. Такой расчет разностей ошибок повторяется для всех строк выборки по очереди. Результаты расчетов усредняются по числу строк выборки.

Пример выбора оптимальной модели для решения задачи распознавания археологических находок

В примере ставятся две цели. Первая - показать, что в случае доопределения модели по смещению, ошибка модели на третьей независимой выборке данных, уменьшается. Вторая – сравнить выбор оптимальной модели с помощью назначения порогового значения модуля коэффициента корреляции, равного 0,3, с более гибким выбором модели по алгоритму самоорганизации модели, где для каждого множества аргументов выбирается свое пороговое значение, которое отвечает минимуму смещения.

Задача распознавания археологических находок подробно описана в [3]. В качестве признаков использованы различные физические свойства находок, образующие 10 первичных признаков. Как вторичные признаки использованы парные ковариации первичных признаков. Исходные данные ранжированы по среднему значению выходной величины и по дисперсии переменных, разделены на две части А и В и бинаризованы, т.е. заменены приближенными значениями +1 или -1.

Для получения моделей применены два метода: дедуктивный метод назначения предельного значения модуля коэффициента корреляции аргумента с выходной переменной, равного 0,3 и индуктивный комбинаторный алгоритм МГУА, называемый алгоритмом самоорганизации модели. Оба метода применены как для множества первичных аргументов, так и для вторичных аргументов, равных парным ковариациям первичных.

Всего получено четыре модели. При самоорганизации индуктивных моделей применено доопределение по критерию смещения.

Если для перебора моделей использовать только один критерий наименьшей ошибки, то получаем модель, имеющую $RR=0,415$; $BS=27,14$. Но если применить доопределение по смещению получаем $RR=0,444$; $BS=0,021$. Небольшое увеличение ошибки приходится допускать, чтобы увеличить свойство обобщения модели. Это свойство приводит к снижению ошибок на других выборках данных, в том числе и при прогнозе.

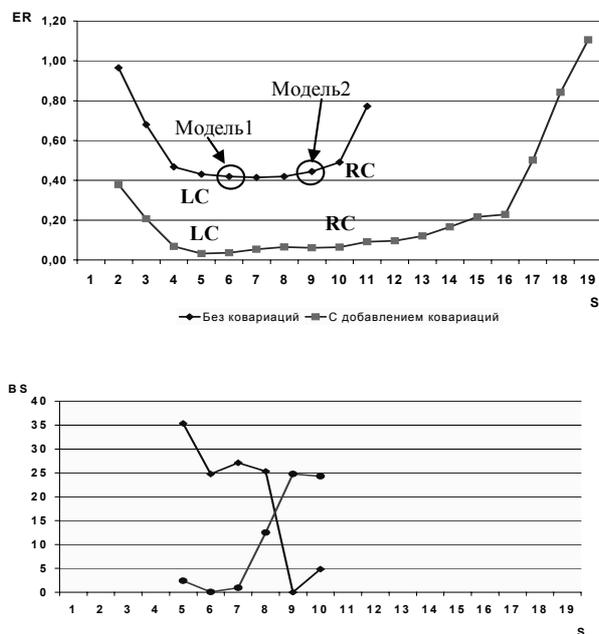


Рис.1. Зависимость точности ER от сложности модели S (верхний график) и доопределение модели по критерию смещения (нижний график).

Разделение информации на две части как принцип совершенствования разнообразных информационных систем

В различных системах принятия решений более совершенными оказываются системы, в которых решения принимаются в результате консенсуса двух частей решающей системы. Это можно проследить как в моделировании, так и в организации экспертных обработок оценок, так и в государственном устройстве общества.

Разделение выборки наблюдений объекта на две части для расчета смещения модели незначительно снижает точность моделей на независимой выборке, но зато повышает ее на всех остальных выборках данных, осуществляющим таким образом, свойство обобщения моделей. Аналогично показанному разделению выборок, разделение экспертов на две независимые группы и выбор лучшего проекта с учетом консенсуса двух экспертных групп, повышает качество оцениваемых проектов. Это было показано в [5] для экспертных оценок проекта перестройки Вроцлавского предместья в г. Прага.

Таким же образом, при выборе конституции демократических государств предусматривается создание двух палатного парламента. Для принятия решений требуется консенсус двух палат, что будет способствовать

усовершенствованию демократического устройства государства.

Заключительные замечания

Образование отдела индуктивного моделирования при Международном центре информационных технологий и систем (заведующий отделом Степашко В.С.), позволило сохранить научные кадры в период перестройки и ускорить подготовку аспирантов и, главное, по новому взглянуть на научную работу по данному направлению. В частности работы по сходимости многоядных итерационных алгоритмов МГУА, по-видимому, не имеют отношения к МГУА, т.к. сходимость перебора по внешнему критерию просто не существует. Эти алгоритмы пропускают много моделей. Для контроля следует рекомендовать применение комбинаторного алгоритма МГУА на вход которого нужно подать 20 - 25 наиболее эффективных первичных и вторичных аргументов, отобранных по модулю коэффициента корреляции с выходной переменной. Комбинаторный алгоритм можно применять для селекции аргументов несколько раз. Актуальным являются вопросы самоорганизации моделей и оценки коэффициентов при неполном эксперименте, т.е. в случаях, когда выборка данных содержит строк меньше, чем аргументов. При оценке коэффициентов при решении таких задач следует вернуться к методам стохастической аппроксимации и градиентного спуска в пространстве оценок.

Литература

1. A.G. Ivakhnenko. Polynomial Theory of Complex Systems // IEEE TRANSACTIONS, MAN, AND CYBERNETICS Vol. SMC-1, № 4, October 1971, pp. 364-378.
2. Ивахненко А.Г. Метод Группового Учета Аргументов – конкурент метода стохастической аппроксимации. – Автоматика, 1968, №3, с. 57-73.
3. Круг Г.М., Круг О.Ю. Математический метод классификации древней керамики // Труды института археологии АН СССР. – Москва: Наука, 1965.-с.317 –323.

Об ассоциативной памяти с безошибочным обучением

С.В. Ильинский, Ю.Г. Сметанин

(Москва)

Основными недостатками ассоциативной памяти на нейронной сети Хопфилда являются сублинейная емкость памяти и возможность появления ложных стационарных точек при обучении. Предложен метод преобразования входных образцов для ассоциативной памяти с помощью кодов, исправляющих ошибки, обеспечивающий возможность построения ассоциативной памяти с экспоненциальной емкостью. Этот подход дает

возможность строить нейронные сети без ложных стационарных точек с помощью стандартного метода внешних произведений.

Задача обучения ассоциативной памяти заключается в построении для заданного набора $A = (a^1, \dots, a^p)$ из p векторов длины n с элементами $(+1, -1)$ такой нейронной сети, в которой векторы из A являются стационарными точками. При этом желательно, чтобы у нейронной сети не было других стационарных точек.

Обучение ассоциативной памяти на нейронной сети Хопфилда основано на корреляционном методе внешних произведений [2]:

$$W = \sum_{k=1}^p W_k, \quad W_k = \{w_{ij}^k\}_{m \times n}, \quad w_{ij}^k = a_i^k a_j^k, \quad k = 1, \dots, p, \quad i, j = 1, \dots, n.$$

Этот метод является безошибочным, когда эталоны ортогональны. Ошибки в нейронных сетях возникают тогда, когда скалярные произведения различных эталонов слишком велики. Известная оценка емкости модели Хопфилда с обучением на основе внешних произведений $p_0 \sim n / \log n$ [4] возникает потому, что p выбранных наугад по схеме Бернулли двоичных векторов при $p < p_0$ почти наверное окажутся расположенными так, что их скалярные произведения будут достаточно малы.

Естественный путь повышения емкости нейронных сетей – увеличение их размерности, то есть построение промежуточного представления с большей длиной. Желательно, чтобы процедура ортогонализации была простой и встроенной в саму нейронную сеть. Этого можно достичь созданием дополнительного слоя с большим числом нейронов, позволяющего строить промежуточные представления большой размерности. Для построения промежуточных представлений целесообразно выбрать код, исправляющий ошибки.

Если u, v – векторы с компонентами $\{+1, -1\}$, отличающиеся в d компонентах, то $(u, v) = N - 2d$. При обучении нейронной сети Хопфилда с помощью метода внешних произведений на основе эталонов

a^1, \dots, a^p для того, чтобы каждый из этих эталонов был состоянием равновесия сети, требуется выполнение неравенств

$$(a^i, a^i) > \sum_{k=1, k \neq i}^p (a^i, a^k), \quad \text{то есть}$$

$$(N - 2d)(p - 1) < N. \quad (1)$$

Это соотношение является основой для выбора кода при заданных n и p : например, для запоминания заданных p эталонов требуется код, у которого

кодирование и длина векторов удовлетворяют соотношению $2d/N > 1 - 1/(p-1)$. Для выбора кода при заданных параметрах можно использовать таблицу наилучших кодов (напр., в [1]).

Выбор наилучшего метода ортогонализации должен производиться с учетом параметров конкретной задачи и по сути ничем не отличается от выбора конкретного кода в системах кодирования.

Для реализации этого метода предложена двухслойная нерекуррентная нейронная сеть. Первый слой системы – препроцессорный, второй – нейронная сеть, реализующая ассоциативную память Хопфилда. Функция первого слоя – преобразование n -мерных двоичных входов в N -мерные векторы, где $N \gg n$. Поскольку емкость нейронной сети Хопфилда – сублинейна, при $N \approx \exp(n)$ емкость системы может быть сделана экспоненциальной.

Нейронная сеть работает следующим образом. Пусть X – входной вектор размерности n , матрица T весов синапсов первого слоя размера $n \times N$ является порождающей матрицей выбранного кода, функция активации нейронов первого слоя f – пороговая, $f_i^T = \begin{cases} 1, \rho(T, X) \leq 1 \\ 0, \rho(T, X) > 1 \end{cases}$, матрица

весов синапсов второго слоя W размера $N \times m$ строится по правилу внешнего произведения эталонов u^p , $p = 1, \dots, m$, g – функция активации нейронов второго слоя g – пороговая со значениями $\{+1, -1\}$, Y – выходной вектор размерности m .

После перекодировки обеспечено выполнение условия (1), следовательно, правило внешних произведений обеспечивает построение ассоциативной памяти, в которой все эталоны действительно являются стационарными точками нейронной сети.

Возможность получения экспоненциальной емкости в описанной модели следует из того, что ее частным случаем является известная модель Канерва [3], в которой используется разреженное случайное кодирование. В ассоциативной памяти Канерва матрица T заполняется нулями и единицами по схеме Бернулли, причем число единиц среди ее элементов мало по сравнению с числом нулей. Экспоненциальность памяти Канерва была доказана ее автором; в дальнейшем оценки были несколько улучшены. Наилучший из известных результатов приведен в [3].

Пример. Пусть $n = 6$. Использование кода Рида – Маллера первого порядка длины 32 позволяет гарантированно запомнить эталоны, соответствующие всем 2^6 векторам длины 6. Для сети Хопфилда с векторами длины 32 оценка емкости ассоциативной памяти при использовании метода внешних произведений – не более 3 эталонов, причем эта оценка является вероятностной.

Для использования описанной модели в качестве автоассоциативной памяти добавляются обратные связи от выходных нейронов к соответствующим им нейронам входного слоя; веса этих связей $w_{ij} = \delta_{ij}, I, j = 1, \dots, n, \delta_{ij}$ – символ Кронеккера. Для доказательства устойчивости работы в рекуррентном режиме используется энергетическая функция

$$E(x) = \sum_{p=1}^m E^p(x), E^p(x) = \sum_{i=0}^{d(u^p, x)} (H(Tu^p), H(Tz^p))$$

где H – функция Хевисайда, $d(u^p, x)$ – расстояние от эталона u^p до x в метрике Хемминга, z^{Pi} получаются последовательной заменой одной координаты в u^p на противоположную, начиная от первой координаты:

$$z^{Pr} = (-u_1^p, \dots, -u_r^p, -u_{r+1}^p, \dots, +u_n^p), r = 0, \dots, n.$$

Эта функция не возрастает на траекториях движения сети, и сеть не может бесконечно долго оставаться в положениях с энергией, отличной от минимума. Отсюда следует асимптотическая устойчивость при любом коде, исправляющем ошибки, использованном для построения матрицы T .

Работа выполнена при поддержке РФФИ, грант 01-01-00052.

Литература

1. Берлекэмп Э. Алгебраическая теория кодирования. М.: Мир, 1971. 477 с.
2. Hopfield J.J. Neural Networks and Physical Systems with Emergent Collective Computational Abilities. // Proc. Nat. Acad. Sci. USA. – 1982. – Vol. 79. – P. 2554 – 2558.
3. Kanerva P. Parallel Structure in Human and Computer Memory. // Neural Networks Comput., Denker, J.S., ed., New York: Am. Inst. Phys. – 1986.
4. McEliece R.J., Posner E.C., Rodemich E. R., Venkatesh S.S. The Capacity of the Hopfield Associative Memory. // IEEE Trans. Inform. Theory. – 1987. – Vol. IT-33. – P. 461 – 482.

Апостериорное совместное обнаружение заданного числа фрагментов в квазипериодической последовательности и ее разбиение на серии одинаковых фрагментов по образцу

А.В. Кельманов, Л.В. Михайлова

(Новосибирск)

Под числовой квазипериодической последовательностью подразумевается всякая числовая последовательность, включающая такие

фрагменты (подпоследовательности подряд расположенных членов), которые имеют характерные детерминированные или стохастические свойства, причем для всех пар следующих друг за другом фрагментов разность между номерами первых членов последующего и предыдущего фрагментов лежит в фиксированном интервале. В работе построен полиномиальный алгоритм апостериорного типа для решения задачи максимально правдоподобного совместного обнаружения заданного числа фрагментов в квазипериодической последовательности и ее разбиения на серии повторяющихся фрагментов по образцу.

Пусть вектор $X = (x_0, \dots, x_{N-1}) \in \mathfrak{R}^N$ зависит от наборов $w = (U_1, \dots, U_L) \in A^L$, $\eta = (n_1, \dots, n_M) \in \Omega_M$, $\delta = (\mu_1, \dots, \mu_L) \in \Delta$, т.е. $X = X(w, \eta, \delta)$, так, что $x_n = \sum_{i=1}^L \sum_{j=\mu_{i-1}+1}^{\mu_i} u_{n-n_j}(i)$, $n = \overline{0, N-1}$, где $u_j(i) = 0$, если $j \neq \overline{0, 1, \dots, q-1}$, $(u_0(i), \dots, u_{q-1}(i)) = U_i$, $i = \overline{1, L}$; причем $A = \{U^{(k)} : U^{(k)} = (u_0^{(k)}, \dots, u_{q-1}^{(k)}) \in \mathfrak{R}^q, 0 < \|U^{(k)}\|^2 < \infty, k = \overline{1, K}\}$, $\Omega_M = \Omega(T_{\min}, T_{\max}, N, q | M) = \{\eta : \eta = (n_1, \dots, n_M); 0 \leq n_1 \leq T_{\max} - q; 0 \leq N - T_{\max} \leq n_M \leq N - q; q \leq T_{\min} \leq n_m - n_{m-1} \leq T_{\max}, m = \overline{2, M}\}$, $\Delta = \Delta(L, M) = \{\delta : \delta = (\mu_1, \dots, \mu_L); 0 = \mu_0 < \mu_1 < \dots < \mu_L = M\}$, $L \leq M$, $M_{\min} \leq M \leq M_{\max}$, $M_{\min} = \lfloor (N - q + 1) / T_{\max} \rfloor$, $M_{\max} = \lfloor (N - 1) / T_{\min} \rfloor + 1$, а T_{\min} и T_{\max} — натуральные числа.

При каждом $i = \overline{1, L}$ последовательность $u_0(i), \dots, u_{q-1}(i)$ называется эталонной последовательностью, вектор U_i — эталонным вектором. Величина q называется длиной эталонной последовательности, множество A — алфавитом эталонных векторов, K — мощностью алфавита. Набор $w = (U_1, \dots, U_L)$ эталонных векторов называется образцом, L — длиной образца. При каждом $m = \overline{1, M}$ подпоследовательность $x_{n_m}, \dots, x_{n_m+q-1}$ последовательности x_n , $n = \overline{0, N-1}$, называется

фрагментом. Величины n_1, \dots, n_M интерпретируются как моменты времени начала фрагментов, а величина M — как число фрагментов в последовательности компонент вектора X . Неравенства $T_{\min} \leq n_m - n_{m-1} \leq T_{\max}$, $m = \overline{2, M}$, — условие квазипериодичности моментов времени начала фрагментов; T_{\min} и T_{\max} — минимальный и максимальный интервалы между двумя последовательными фрагментами, M_{\min} и M_{\max} — минимальное и максимальное число фрагментов в последовательности.

Каждому эталонному вектору, входящему в образец w , в квазипериодической последовательности соответствует серия одинаковых фрагментов, причем величине j соответствует порядковый номер фрагмента, а величине i — порядковый номер серии. При каждом $i = \overline{1, L}$ разность $\mu_i - \mu_{i-1}$ определяет число фрагментов, входящих в i -ую серию, величина $\mu_{i-1} + 1$ — порядковый номер фрагмента, начинающего i -ую серию, а величина μ_i — порядковый номер фрагмента, завершающего эту серию. Компоненты набора η соответствуют моментам времени начала эталонных фрагментов, а по компонентам набора δ определяется разбиение квазипериодической последовательности на серии по образцу w . Последовательность компонент вектора X — квазипериодическая последовательность, порожденная по образцу w .

Допустим, что образец $w = (U_1, \dots, U_L)$ зафиксирован. Пусть случайный вектор $Y = (y_0, \dots, y_{N-1})$ есть сумма двух независимых векторов: $Y = X(\eta, \delta | w) + E$, где $E = (\varepsilon_0, \dots, \varepsilon_{N-1}) \in \Phi_{0, \sigma^2 I}$; через

$\Phi_{0, \sigma^2 I}$ обозначено нормальное распределение с параметрами $(0, \sigma^2 I)$.

Задача совместного обнаружения и разбиения по образцу состоит в том, чтобы по наблюдаемому вектору Y определить наборы η и δ , в соответствии с которыми был порожден ненаблюдаемый вектор $X(\eta, \delta | w)$. Параметры задачи N, T_{\min}, T_{\max}, M и q считаются известными.

В качестве примера в верхней части Рис. 1 приведен алфавит, включающий 3 эталонных вектора и образец w длины 4; в средней части изображена квазипериодическая последовательность, включающая 9

фрагментов, порожденная по образцу w ; каждый элемент образца порождает в квазипериодической последовательности однородный участок — серию одинаковых фрагментов, причем серии упорядочены так же, как элементы образца; порожденные серии включают 2, 1, 3 и 3 фрагмента соответственно; нижняя часть рисунка содержит график зашумленной квазипериодической последовательности, подлежащей обработке.

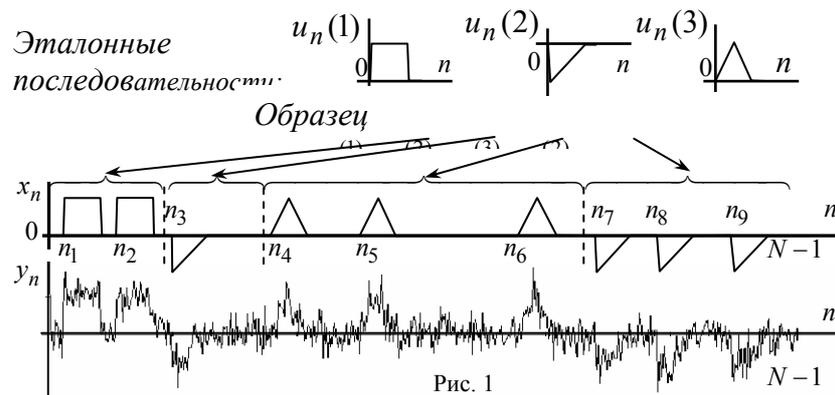


Рис. 1

Показано, что задача совместного обнаружения и разбиения сводится к задаче проверки совокупности простых гипотез о среднем случайного гауссовского вектора, причем мощность этой совокупности экспоненциально растет с ростом длины обрабатываемой последовательности, так что прямой перебор множества гипотез не представляется возможным. Построен полиномиальный алгоритм отыскания оптимальной, максимально правдоподобной гипотезы. Ядром алгоритма является решение задачи минимизации аддитивной сепарабельной целевой функции с ограничениями в виде линейных неравенств. Получены необходимые и достаточные условия корректной постановки задачи и рекуррентные формулы пошаговой оптимизации, обеспечивающие отыскание глобального экстремума. Результаты численного моделирования подтверждают эффективность предложенного алгоритма в условиях интенсивных помех.

Работа выполнена при поддержке РФФИ, проект № 03-01-00036.

Максимально правдоподобное апостериорное обнаружение квазипериодически повторяющегося фрагмента числовой последовательности в условиях шума и потери данных

А.В. Кельманов, С.А. Хамидуллин
(Новосибирск)

Рассматривается задача апостериорного максимально правдоподобного обнаружения повторяющегося эталонного фрагмента в числовой последовательности. Анализируется случай, когда повторы квазипериодичны. Предполагается, что: 1) число повторов фрагмента в последовательности неизвестно; номер члена последовательности, соответствующий началу фрагмента, – детерминированная (не случайная) величина; 2) повторяющийся фрагмент подвергается искажениям в виде обнуления первых и/или последних членов; число обнуляемых членов – детерминированная, но неизвестная величина, которая изменяется от фрагмента к фрагменту; обнуление интерпретируется как потеря данных об эталонном фрагменте; 3) искаженная последовательность зашумлена аддитивной гауссовской некоррелированной помехой.

Задачи обнаружения и распознавания, при постановке которых предполагалось, что искажения (обнуления) эталонного фрагмента слева и справа допустимы, рассмотрены в [1,2]. Однако в этих работах проанализирован случай заданного числа фрагментов в последовательности. Решение задачи помехоустойчивого обнаружения для случая неизвестного числа фрагментов в условиях потери данных приведено в настоящей работе.

Пусть вектор $X = (x_0, \dots, x_{N-1}) \in \mathfrak{R}^N$ зависит от векторов $U = (u_0, \dots, u_{q-1}) \in \mathfrak{R}^q$ и $\eta = (n_1, \dots, n_M) \in \Omega$, т.е. $X = X(\eta, U)$, так, что $x_n = \sum_{m=1}^M u_{n-n_m}$, $n=0, \dots, N-1$, где $u_j = 0$, если $j \neq 0, \dots, q-1$, причем $0 < \|U\|^2 < \infty$, $\Omega = \Omega(N, T_{\min}, T_{\max}, q) = \{\eta : \eta = (n_1, \dots, n_M); 0 \leq n_1 \leq T_{\max} - q; 0 \leq N - T_{\max} \leq n_M \leq N - q; q \leq T_{\min} \leq n_m - n_{m-1} \leq T_{\max}, m = 2, \dots, M\}$, а T_{\max} и T_{\min} – натуральные числа.

Последовательность u_0, \dots, u_{q-1} компонент вектора U называется эталонной последовательностью, q – длиной эталонной последовательности, а вектор U – эталонным вектором; подпоследовательность $x_{n_m}, \dots, x_{n_m+q-1}$, $m = 1, \dots, M$,

последовательности x_n , $n=0, \dots, N-1$. называется *фрагментом*. Величины n_1, \dots, n_M интерпретируются как моменты времени начала фрагментов, а величина M – как число фрагментов в последовательности компонент вектора X . Неравенства $T_{\min} \leq n_m - n_{m-1} \leq T_{\max}$, $m=2, \dots, M$, – условие квазипериодичности моментов времени начал фрагментов; T_{\min} и T_{\max} – минимальный и максимальный интервалы между двумя последовательными фрагментами.

Подпоследовательность u_{q^-}, \dots, u_{q^+} эталонной последовательности $u_0, \dots, u_{q^-}, \dots, u_{q^+}, \dots, u_{q-1}$, где $(q^-, q^+) \in Q = \{(q^-, q^+) : 0 \leq q^- \leq q^+ \leq q-1\}$, называется *усеченной* эталонной последовательностью, а q^- и q^+ – левой и правой *границами усечения* соответственно. Последовательность

$$\tilde{u}_j = \tilde{u}_j(q^-, q^+, u_j) = \begin{cases} u_j, & j = q^-, \dots, q^+, \\ 0, & j = 0, \dots, q^- - 1, j = q^+ + 1, \dots, q-1, \end{cases}$$

называется *искаженной* эталонной последовательностью, а вектор $\tilde{U} = (\tilde{u}_0, \dots, \tilde{u}_{q-1}) = \tilde{U}(q^-, q^+, U)$ – *искаженным* эталонным вектором.

Пусть компоненты вектора $\tilde{X} = (\tilde{x}_0, \dots, \tilde{x}_{N-1})$ образуют последовательность $\tilde{x}_n = \sum_{m=1}^M \tilde{u}_{n-n_m}(q_m^-, q_m^+, u_{n-n_m})$, $n=0, \dots, N-1$, где $\tilde{u}_j = 0$, если $j \neq 0, \dots, q-1$, причем $((q_1^-, q_1^+), \dots, (q_M^-, q_M^+)) = \xi \in Q^M$. Тогда вектор $\tilde{X} = \tilde{X}(\eta, \xi, U)$ $\tilde{X}(\eta, \xi, X(\eta, U))$ есть искаженный вектор X или вектор, порожденный векторами U , η и набором ξ пар границ усечения эталонного фрагмента.

Задача обнаружения состоит в том, чтобы по наблюдаемому вектору $Y = \tilde{X}(\eta, \xi | U) + E$, где $E \in \Phi_{0, \sigma^2 I}$, найти вектор η , включающий неизвестное число M компонент, в соответствии с которым были порождены ненаблюдаемые векторы $\tilde{X}(\eta, \xi | U)$ и $X(\eta | U)$. Параметры

задачи N, T_{\min}, T_{\max}, q и вектор U предполагаются известными. Набор ξ рассматривается как неизвестный мешающий параметр.

Решение задачи в целом разбито на последовательное решение нескольких взаимосвязанных подзадач. Сначала установлено необходимое и достаточное условие корректной постановки задачи, которое связывает между собой ее параметры. Затем показано, что сущность задачи обнаружения состоит в проверке совокупности гипотез о среднем \tilde{X} случайного гауссовского вектора Y ; причем, специфика задачи состоит в том, что мощность анализируемой совокупности растет экспоненциально с увеличением размерности вектора или длины последовательности. Ввиду указанной специфики, прямой перебор гипотез из этой совокупности не представляется возможным. Поэтому проблема решается алгоритмически.

В работе доказано, что алгоритмический поиск максимально правдоподобной гипотезы сводится к минимизации целевой функции

$$S(\eta, \xi) = \sum_{m=1}^M \sum_{j=q_m^-}^{q_m^+} \{u_j^2 - 2y_{j+n_m} u_j\} \rightarrow \min_{(\eta, \xi)},$$

где наборы $\eta \in \Omega$ и $\xi \in Q^M$ имеют одну и ту же неизвестную размерность M . Раскрыта трехэтапная структура алгоритма минимизации этой функции. Получены рекуррентные формулы пошаговой оптимизации, гарантирующие максимально правдоподобное обнаружение. Затем показано, что рекуррентные формулы обеспечивают решение задачи за полиномиальное время. Даны оценки временной и емкостной сложности алгоритма, устанавливающие взаимосвязь между параметрами задачи и необходимыми для ее решения ресурсами по памяти и времени. Наконец, результатами численного моделирования продемонстрирована эффективность и помехоустойчивость алгоритма.

Работа выполнена при поддержке РФФИ, проект № 03-01-00036.

Литература

1. Кельманов А. В., Хамидуллин С. А. Апостериорное обнаружение заданного числа усеченных подпоследовательностей в квазипериодической последовательности // Сиб. журн. индустр. математики. 2000. Т. 3, № 1(5). С.137-156.
2. Кельманов А. В., Хамидуллин С. А. Распознавание квазипериодической последовательности, образованной из заданного числа усеченных подпоследовательностей // Сиб. журн. индустр. математики. 2002. Т.5, №1(9). С. 85-104.

Динамика модели роста под действием возмущающих факторов

Л.О. Кириченко, О.И. Синельникова
(Харьков)

Введение

В последние годы большой интерес вызывают одномерные итерационные отображения, которые выступают, с одной стороны, как упрощенные модели множества различных процессов, а другой стороны, как язык, на котором можно говорить о многих сложных явлениях. Кроме того, в настоящее время быстрыми темпами развивается синергетическая экономика, которая занимается исследованием таких сложных явлений, как экономические циклы, экономический хаос, образование урбанистических структур, случайность в экономической эволюции и др. При этом многие модели экономических явлений и процессов сводятся к достаточно простым одномерным отображениям [1].

На любую реальную динамическую систему действуют случайные возмущения. Воздействие флуктуаций на режимы нелинейных систем приводит к эффектам двух типов. Под действием внешних возмущений может наблюдаться сдвиг в пространстве управляющих параметров бифуркационной диаграммы. При этом не исключено исчезновение определённой мелкомасштабной структуры бифуркационной диаграммы, однако принципиально новые режимы не возникают. Другой тип бифуркационных явлений связан с вызванными внешними возмущениями режимами, которые в невозмущенной системе вовсе не имеют места. Целью исследований в рамках данной работы, является ответы на вопросы: как повлияет учет флуктуаций в модели процесса на ход эволюции системы, могут ли под действием возмущений возникнуть новые режимы.

Математическая модель

Одной из математических моделей, используемых в экономическом анализе, является макроэкономическая модель роста населения Хаавельмо [2]:

$$\frac{dN}{dt} = N \left(a - \frac{\beta N}{Y} \right), \quad a, \beta > 0, \quad (1)$$

$$Y = AN^\alpha, \quad A > 0, \quad 0 < \alpha < 1,$$

где N – численность населения, Y – реальный объем производства, a , β , α и A – константы, соответствующие определенным экономическим показателям. Закон роста представляет собой обобщение аналогичной логистической формы, широко используемой в теории биологических

популяций и экономическом анализе.

Если ввести дискретное время и заменить производные по времени первыми разностями, то (1) можно привести к виду

$$x_{t+1} = (1 + a)x_t(1 - x_t^{1-\alpha}) = F(x_t; a, \alpha). \quad (2)$$

Метод исследования

Отображения, исследуемые в рамках данной работы, принадлежат определённому классу функций $f(x, \mu)$. Такие отображения имеют вид параболы, описывая однозначное, но не взаимнооднозначное, преобразование отрезка в себя. При изменении управляющего параметра для данных отображений наблюдается каскад бифуркаций удвоения периода по сценарию Фейгенбаума. [3]

Одномерное отображение (2) в присутствии аддитивных возмущений в общем виде можно описать следующим образом:

$$x_{n+1} = f(x_n, a, \varepsilon), \quad (3)$$

где ε - случайное воздействие.

При моделировании возмущений, действующих на систему, следует различать две ситуации: движение по параметрам в присутствии внешних флуктуаций заданной интенсивности и вариация интенсивности возмущений при фиксированных заданных параметрах системы. Интенсивность возмущений в определенном смысле здесь играет роль управляющего параметра. [4]

Влияние случайного возмущения в отображении может происходить одним из трех возможных случаев: воздействию флуктуации подвергается исследуемая величина, управляющий параметр или случайное воздействие влияет на всю систему в целом.

Целью исследования является выявление изменений в эволюции системы при воздействии на неё возмущающих факторов. В рассматриваемом отображении случайное воздействие выступает управляющим параметром, и необходимо выяснить, могут ли быть под действием этого параметра индуцированы качественно новые переходы. В качестве модели шума рассматривается $\varepsilon = d\xi(w)$, где d - интенсивность шума; $\xi(w)$ - нормально распределенная случайная величина, с заданным математическим ожиданием $\bar{\xi}$ и дисперсией σ_{ξ}^2 [5].

С учетом случайных возмущений получены бифуркационные диаграммы, из которых видно, что в присутствии аддитивного возмущающего воздействия наблюдается сдвиг в пространстве управляющих параметров, исчезает мелкомасштабная структура бифуркационной диаграммы, но принципиально новых режимов, которые бы отсутствовали в

детерминированной системе, не возникает (рис. 1). Такой результат достаточно предсказуем, однако возникает вопрос: в каком направлении происходит сдвиг точки бифуркации, и при каком значении параметра бифуркация наступает в данном случае. Кроме того, принципиален вопрос формулировки критерия точки бифуркации с учетом случайного воздействия.

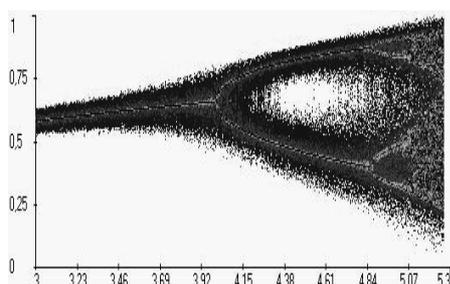


Рис. 1. Бифуркационная диаграмма при наличии случайных воздействий

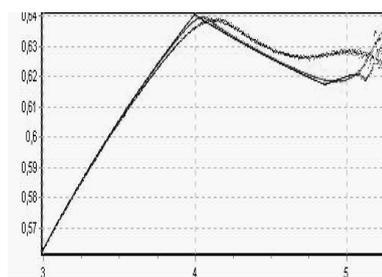


Рис. 2. Усредненная бифуркационная диаграмма при разных случайных воздействиях возмущений

Для решения этих вопросов была построена усредненная бифуркационная диаграмма, которая получается из обычной в результате того, что выводятся не все точки временной реализации для данного значения параметра, а их среднестатистическое значение (рис. 2).

Для детерминированной системы, без случайного воздействия, точка бифуркации определяется значением параметра, при котором производная меняет знак. Численное моделирование возмущаемой системы не позволяет найти точку, в которой производная меняет знак, так как эта точка «размывается» в некоторую область. Однако из усредненной диаграммы наглядно видно, в каком направлении происходит смещение бифуркационной диаграммы под действием случайного воздействия и можно численно определить значения параметра, при которых происходит бифуркация.

Литература

1. Анищенко В.С. Сложные колебания в простых системах. -М.: Наука, 1990.- 311 с.
2. Занг В.-Б. Синергетическая экономика. Время и перемены в нелинейной экономической теории.- М.: Мир, 1999.-335 с.
3. Хакен Г. Синергетика. -М.: Мир, 1980.-480 с.
4. Шустер Г. Детерминированный хаос: Введение. -М.:Мир, 1988.-240 с.
5. Вентцель А.Д., Фрейдлин М.И. Флуктуации в динамических системах под действием малых случайных возмущений. -М.: Физматгиз, 1973. - 424 с.

Генетический алгоритм поиска логических закономерностей по прецедентам для решения задач распознавания

Н.В. Ковшов, В.В. Рязанов
(Москва)

Общая постановка задачи

Рассматривается задача распознавания в стандартной постановке и комбинаторно-логический подход для ее решения [1].

Алгоритмы вычисления оценок предполагают использование систем опорных множеств алгоритма (частичных прецедентов), по которым осуществляется сравнение распознаваемых объектов с эталонными. Задача нахождения по прецедентам систем «информативных» опорных множеств (тупиковых тестов, представительных наборов, логических закономерностей, синдром-признаков) является наиболее трудоемким этапом построения распознающего алгоритма. Так, в методе [2] приближенного поиска логических закономерностей требуется решение последовательности задач целочисленного линейного программирования, а в методе [3] - решение задач поиска максимальной совместной подсистемы системы линейных уравнений относительно дискретных переменных при ограничениях в виде системы линейных неравенств. В данной работе предложен новый метод поиска логических закономерностей классов, основанный на идеях генетических алгоритмов оптимизации. Исходная популяция формируется как некоторый набор подмножеств эталонов класса. Каждому элементу популяции ставится в соответствие бинарный код, специальный предикат и значение ценовой функции. Логическая закономерность класса – предикат с максимальным значением ценовой функции - находится с помощью генетического алгоритма.

Поиск логических закономерностей в процессе обучения

Рассмотрим следующее параметрическое множество элементарных

$$\text{предикатов: } P(c_j^1, c_j^2, x_j) = \begin{cases} 1, & c_j^1 \leq x_j \leq c_j^2 \\ 0, & \text{иначе.} \end{cases}$$

Здесь $-\infty \leq c_j^1 \leq c_j^2 \leq \infty, j = 1, 2, \dots, n$, - параметры предикатов. Пусть

$$N_i = \{S_{i_1}, S_{i_2}, \dots, S_{i_k}\} - \text{некоторый набор объектов класса } K_i.$$

Построим предикат $P_{N_i}(S) = \& P(c_j^1, c_j^2, x_j), j = 1, 2, \dots, n$,

$S = (x_1, x_2, \dots, x_n)$, следующим образом: в качестве верхних и нижних

границ предиката по каждому признаку возьмем соответственно наибольшее и наименьшее значение данного признака среди объектов набора N_i , то есть

$$c_j^1 = \underset{S \in N_i}{\text{Min}}(x_j), c_j^2 = \underset{S \in N_i}{\text{Max}}(x_j).$$

На рис 1 показаны примеры построения предиката. Точками обозначены объекты рассматриваемого класса, крестиками – объекты остальных классов.

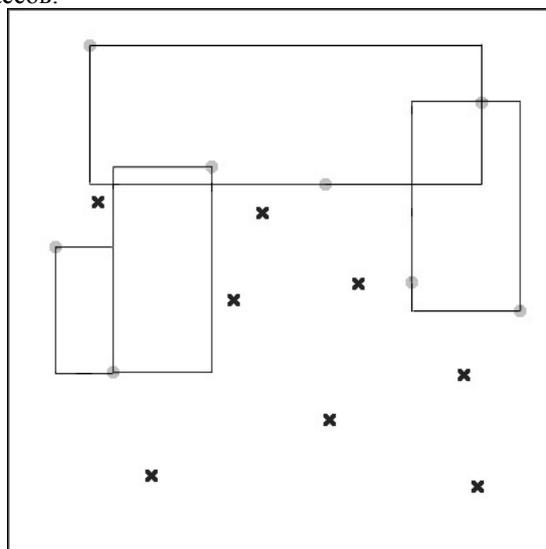


Рис. 1. Иллюстрация принципа построения предикатов.

Таким образом, каждому предикату соответствует некоторый набор объектов одного класса (на которых предикат принимает значение 1), а каждый набор объектов формирует единственный предикат. Алгоритм производит для каждого класса поиск предикатов, соответствующих заданному критерию оптимальности до тех пор, пока такие предикаты существуют.

В качестве критерия оптимальности использовалась модификация стандартного критерия оптимальности, в которой значение критерия равно 0 в том случае, когда среди объектов класса K_i , формирующих предикат P_i , нет ни одного, который бы не участвовал в формировании предикатов на предыдущих шагах.

Поиск предиката, соответствующего оптимуму критерия оптимальности, производится следующим образом. Для некоторого класса K_i создается

множество бинарных строк длиной k , где k - это количество объектов в классе. Каждая строка описывает соответствующий предикат: если значение j -го бита строки - «истина», значит j -ый элемент класса K_i участвует в формировании предиката P_i и не участвует в противном случае. Таким образом, каждой бинарной строке ставится в соответствие один единственный предикат и для поиска экстремума ценовой функции – критерия оптимальности, можно воспользоваться генетическим алгоритмом. [4-5]. Генетический алгоритм находит оптимальные предикаты и записывает их в таблицу предикатов.

Процесс распознавания

Классификация (распознавание) новых объектов осуществляется с помощью голосования по трем вариантам вычисления оценок за классы.

1-й вариант вычисления оценок основан на подсчете количества предикатов, которым удовлетворяет распознаваемый объект.

2-й вариант вычисления оценок основан на подсчете количества допустимых предикатов, которые формируются эталонными объектами заданного класса вместе с распознаваемым объектом.

3-й вариант вычисления оценок основан на подсчете количества признаков для каждого предиката из таблицы предикатов, при удалении которых распознаваемый объект не будет удовлетворять данному предикату.

Настоящая работа выполнена при поддержке Российского фонда фундаментальных исследований (проекты №02-01-08007, 02-01-00558, 02-07-90134, 02-07-90137, 03-01-00580), Программ №7, 17 фундаментальных исследований Президиума РАН,

Литература

1. Журавлев Ю.И. «Об алгебраическом подходе к решению задач распознавания или классификации». Проблемы кибернетики, Наука, Москва, 1978, вып. 33, стр. 5-68.
2. V.V.Ryazanov, "Recognition Algorithms Based on Local Optimality Criteria", Pattern Recognition and Image Analysis, 4, 2, (1994), 98-109.
3. Ryazanov V.V. About some approach for automatic knowledge extraction from precedent data // Proceedings of the 7th international conference "Pattern recognition and image processing", Minsk, May 21-23, 2003, vol. 2, pp. 35-40.
4. Батищев Д.И. Генетические алгоритмы решения экстремальных задач: Учебное пособие. Воронеж, 1995. 69 с.
5. Учебное пособие по курсу «Генетические методы оптимизации» под редакцией В.М. Курейчика. Москва 1996.

Адаптивный алгоритм распознавания образов на основе оптимальных тупиковых нечётких тестов и синдромов

И.В. Котельников

(Нижний Новгород)

Большинство алгоритмов, предназначенных для построения решающих правил распознавания образов, предполагает в качестве входной информации конечную обучающую выборку объектов (ОВ)

$$\{X^i(x_1^i, x_2^i, \dots, x_\nu^i, \dots, x_n^i, \pi^i), i = \overline{1, M}\},$$

где X^i - объект с порядковым номером i в выборке, $x_\nu^i, \nu = \overline{1, n}$, - значения n признаков объекта X^i , π^i - номер класса π , которому принадлежит объект X^i , $\pi \in \{1, 2, \dots, K\}, K \geq 2$, где K - число классов, а M - число объектов в ОВ. В этих условиях при получении некоторого дополнительного множества объектов для построения решающего правила приходится повторять всю процедуру его построения заново на новой выборке объектов, включая дополнительные. Аналогичные действия приходится выполнять при необходимости исключения некоторого множества объектов из ОВ. При обработке потоковых данных со временем активно увеличивается объём ОВ, трудоёмкость и время обработки данных алгоритмом построения решающего правила. Решение проблемы в таких случаях обычно ищут в разработке адаптивных алгоритмов построения решающего правила, которые эффективно используют результаты, полученные на уже прошедшей через систему обработки данных ОВ. Алгоритм построения решающего правила в таких случаях строят как некую корректирующую процедуру имеющегося решающего правила.

Метод распознавания образов на основе оптимальных тупиковых нечётких тестов и синдромов [1], как оказалось, исключительно приспособлен для разработки адаптивных алгоритмов. Основным свойством метода, обеспечивающим такую приспособленность, является полное описание ОВ в решающем правиле небольшим числом синдромов. Под синдромом понимается сочетание из $k_s \leq n$ признаков описания объектов $x_{i_\nu}, \nu = \overline{1, k_s}, i_\nu \in \{1, 2, \dots, n\}$ с известными границами их изменчивости

$$a_{i_\nu} \leq x_{i_\nu} \leq b_{i_\nu}, \nu = \overline{1, k_s}, \quad (1)$$

которым удовлетворяет группа объектов *какого-то одного и только этого класса*, а a_{i_ν} и b_{i_ν} - некоторые константы, свои для каждого из

признаков. В n -мерном пространстве признаков синдрому соответствует k_s -мерный прямоугольный параллелепипед P^{k_s} , на поверхности и во внутренней области которого располагаются объекты только соответствующего синдрому класса и нет ни одного объекта другого класса. В силу этого свойства такие синдромы называются *абсолютными*. Построение абсолютных синдромов, как решение самостоятельной задачи, довольно непросто. Однако математический аппарат оптимальных тупиковых нечётких тестов позволяет легко обойти эти трудности благодаря адекватности понятий синдрома и теста, который по своему основному свойству тоже является описанием множества объектов, принадлежащих одному и тому же классу. Поскольку построение тестов уже формализовано [2], то после построения теста и определения описываемой им группы объектов одного класса построение синдрома превращается в очень простую задачу определения интервалов (1), минимальным образом покрывающим выделенную группу объектов по каждому из тестовых признаков. Таким образом, построив тесты и синдромы на ОВ, группу объектов класса, соответствующую конкретному синдрому, можно рассматривать, как некий единичный объект класса, имеющий в пространстве признаков не точечное, а пространственное описание. Отметим, что такое представление является более общим и для отдельного единичного объекта в пространстве признаков, который можно рассматривать как n -мерный синдром со знаком равенства $a_{i_v} = b_{i_v}$ в (1) по всем n признакам.

Переход к отмеченному выше более общему описанию объектов выборки синдромами приводит к замене формулы подсчёта различимости μ объектов X^i и X^j по признаку x_v [1]

$$\mu / x_v = \left| x_v^i - x_v^j \right| / D_v,$$

где D_v - диаметр признака x_v , или его изменчивость на множестве объектов ОВ, формулой

$$\mu / x_v = \begin{cases} (a_v^i - b_v^j) / D_v & \text{при } a_v^i > b_v^j \\ (a_v^j - b_v^i) / D_v & \text{при } a_v^j > b_v^i \\ 0 & \text{при } a_v^j \leq b_v^i \vee a_v^i \leq b_v^j \end{cases}.$$

При такой замене различимость между единичными объектами и синдромами подсчитывается единообразно при любом их сочетании: единичный объект с единичным, единичный объект с синдромом, синдром с

синдромом.

Работа адаптивного алгоритма в новых условиях при пополнении ОБ может быть представлена следующим образом. Пусть на вход алгоритма поступил очередной объект пополнения ОБ. Он подаётся на вход решающего правила. Если объект принадлежит синдрому своего класса, то коррекция решающего правила будет состоять в увеличении на единицу числа объектов m , имеющих данный синдром. Аналогичной коррекции решающее правило подвергается и в случае пополнения выборки группой объектов, описываемой синдромом. Число объектов синдрома решающего правила увеличивается на число m объектов синдрома пополнения. Однако при этом должно выполняться условие полного покрытия синдрома пополнения синдромом решающего правила того же класса. При выполнении тех же условий аналогичным образом можно произвести исключение из ОБ отдельного объекта или группы объектов, описываемых синдромом, с соответствующим уменьшением числа m объектов в синдроме решающего правила. В случае если объект не принадлежит ни одному из синдромов решающего правила своего класса или группа объектов, описываемая синдромом, не покрывается полностью синдромом решающего правила того же класса, требуется построение заново решающего правила. Но такое решающее правило будет строиться на исключительно малой выборке, состоящей из пространственных объектов, соответствующих синдрому имеющегося решающего правила, и объектов пополнения или исключения. Такое построение отличается малой трудоёмкостью и малым временем выполнения процедуры.

Аналогичный алгоритм можно построить и для распознавания образов без учителя, или кластерного анализа объектов. Для этого вначале решается задача кластеризации для представительной выборки объектов и на полученных кластерах строится решающее правило их распознавания на основе нечётких тестов и синдромов. Дальнейшая работа по кластеризации объектов с пополнением и исключением объектов из выборки сводится к рассмотренному выше адаптивному алгоритму распознавания. Отличие будет состоять лишь в том, что объекты пополнения и исключения не будут иметь признака класса и будут получать его по принадлежности синдромам решающего правила или по наибольшему сходству с ними.

Работа выполнена при финансовой поддержке РФФИ, проект 02-01-00274.

Литература

1. Kotel'nikov I.V. A Syndrom Recognition Method Based on Optimal Irreducible Fuzzy Tests// Pattern Recognition and Image Analysis, Vol. 11, No. 3, 2001, pp. 553-559.
2. Котельников И.В. Алгоритмы построения тупиковых нечётких тестов// Динамика систем. / Межвузовский сборник научных трудов под ред.

Неймарка Ю.И., изд. ННГУ, Н.Новгород, 1995, С.71-86.

Нейронные сети максимальной устойчивости как альтернатива робастным нейронным сетям.

В.В. Крепец
(Москва)

Введение

Многие методы построения, казалось бы, устойчивых нейросетевых моделей, основывающихся на реальных данных, далеко не всегда дают исследователю желаемые результаты. Несовпадение желаемого и фактического, как правило, обусловлено несоблюдением тех или иных условий или ограничений, в рамках которых эффективны те или иные методы или приемы. Особенно это сказывается при решении некорректно поставленных задач, а также задач высокой размерности. В работе с помощью численного моделирования на искусственно созданной выборке показано, как с использованием оценок максимальной устойчивости (далее ОМУ) можно добиться лучших результатов, чем с использованием робастных оценок. Следуя принципам преемственности, будем называть нейронные сети, использующие ОМУ, нейронными сетями максимальной устойчивости.

Теоретическая часть

Большинство устойчивых методов базируется на решении задачи

$$\sum_i \varphi(y^i - \Theta x^i) \rightarrow \min \quad (1)$$

где x – вектор независимых переменных, y – результирующая переменная (отклик), Θ – вектор параметров, φ – локально выпуклая функция.

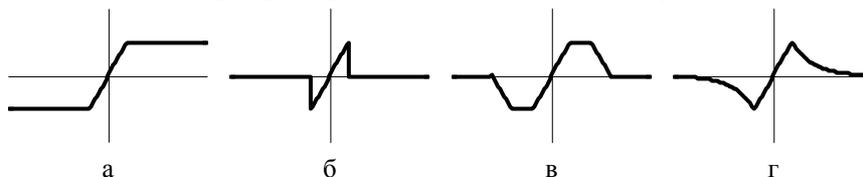


Рис. 1.

Существует два различных способа получения робастных оценок [1-4] и робастных нейронных сетей. Во-первых, добавлением функций влияния [5,6] или, во-вторых, суперпозицией нелинейных функций вида $\varphi(t) = \varphi_1(\varphi_2(t))$, где $\varphi_1(u) = u^2$, а в качестве φ_2 может использоваться одно из преобразований, графики которых приведены на рисунке 1 (а-г). Использование в качестве $\varphi_2(t)$ функции, график которой приведен на

рисунке 1а, дает робастную оценку Хьюбера.

Рассмотрим параметрическое семейство оценок Мешалкина [7] с оценочными функциями вида $\xi(x) = x \exp(-\lambda x^2 / 2)$, где $\lambda > 0$ – параметр. Использование в качестве $\varphi(t)$ функции из этого семейства при $\lambda = 1$ дает ОМУ. Свойство этой оценки изложены в книге А.М. Шурыгина [4].

Использование робастного оценивания параметров при обучении нейронных сетей прямого распространения представляется достаточно логичным. На примере численного моделирования показано, какие результаты дает использование ОМУ при обучении нейронных сетей прямого распространения. Обучение нейронных сетей прямого распространения, базируется на решении задачи

$$\sum_i \varphi(y^i - \psi(\Theta, x^i)) \rightarrow \min, \quad (2)$$

где сохранены те же обозначения, а через $\psi(\cdot)$ обозначена функция, вычисляемая нейронной сетью. Чтобы получить оценку максимальной устойчивости для параметров нейронной сети прямого распространения необходимо решить следующую задачу минимизации

$$\sum_i -\exp\left\{-\left[y^i - \psi(\Theta, x^i)\right]^2 / 2\right\} \rightarrow \min, \quad (3)$$

Все эти оценки, и соответствующие им нейронные сети, могут быть реализованы с помощью Neural Network Constructor [8-10].

Пример численного моделирования

Численное моделирование проводилось на искусственно созданной выборке, содержащей 20 наблюдений, каждое из которых описывалось 8 дескрипторами. Каждое $x_j^i : i = 1, 2, \dots, 20; j = 1, 2, \dots, 8$ представляло собой произведение двух независимых случайных величин, имеющих нормальное распределение $N(0;3)$. Результирующая переменная была определена следующим образом:

$$y^i = \sum_{j=1}^8 x_j^i + \varepsilon^i, \quad (4)$$

где ошибка ε^i также имела нормальное распределение $N(0;3)$. В матрицу исходных данных целенаправленно были введены две большие погрешности. Это $\varepsilon^{17} = 30$ и $\varepsilon^{18} = 15$.

Было найдено 3 оценки параметров моделей: оценка максимального правдоподобия (далее ОМП), робастная оценка, полученная с

использованием описанной в [6] функции влияния, и ОМУ. В рассматриваемом случае оказалось, что робастная оценка не сильно отличается от ОМП, поскольку 17 и 18 наблюдения не располагаются «далеко» от вектора оценки центра выборки. Ниже на рисунке 2 (а,б) приведены диаграммы рассеяния для робастной модели и модели максимальной устойчивости. В таблице 1 приведены некоторые расчетные характеристики построенных моделей.

Таблица 1. Расчетные характеристики построенных моделей.

Оценка	R^2	σ^2	s^2	R	eff Θ	stb Θ
ОМП	0,97	3,29	8,79	5,50	1,00	0,00
Робастная	0,97	3,29	8,67	5,37	1,00	0,02
ОМУ	0,92	6,56	6,65	0,09	0,50	1,00

В таблице используются следующие обозначения: R^2 – квадрат парного коэффициента корреляции между множеством наблюдаемых и расчетных величин, σ^2 – среднеквадратичная ошибка модели, s^2 – среднеквадратичная ошибка при скользящем контроле, R – погрешность модели за счет оценки параметров, eff Θ – эффективность оценки и stb Θ – устойчивость оценки. Последние три показателя определены и исследованы в работах [2-4].

Робастная модель оказалась не способной распознать в 8-мерном пространстве 2 большие ошибки, введенные в исходные данные. Модель, использующая оценку максимальной устойчивости, исправила ошибку ε^{17} , но оказалась не в состоянии выявить и исправить в два раза меньшую ошибку ε^{18} . Снижение эффективности модели, использующей ОМУ, компенсируется заметным увеличением устойчивости.

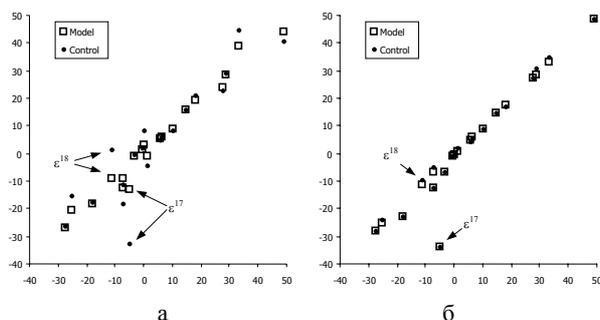


Рис. 2. Диаграммы рассеяния для построенных моделей.

Несмотря на большую, чем у ОМП устойчивость робастных методов оценивания (пример этой устойчивости описан в [6]) существуют и другие методы оценивания параметров нейронных сетей (в частности нейронные сети, использующие оценку максимальной устойчивости параметров),

которые еще более устойчивы к ошибкам в исходных данных. Как правило, робастные нейронные сети, как и другие робастные методы оценивания корректны, когда выполняется предположение о низкой размерности пространства признаков. Свойства робастных нейронных сетей проявляются в полной мере при $p/n \rightarrow 0$ при неограниченном росте n , где p – количество дескрипторов, которыми описывается конечная выборка, а n – количество наблюдений в этой выборке [1,5,6].

Вывод

При решении прикладных задач в различных предметных областях наиболее логичным представляется использовать нейронные сети, использующие оценку максимальной устойчивости параметров совместно с другими устойчивыми методами оценивания. Это обуславливается незначительным количеством наблюдений в экспериментальных данных, а нейронные сети, использующие оценку максимальной устойчивости параметров, проявляют свои свойства как раз на выборках небольшого объема. Именно в этих условиях следует отдавать предпочтение нейронным сетям, использующим оценку максимальной устойчивости параметров.

Литература

1. Хьюбер П. Робастность в статистике. – М.: Мир, 1984.
2. Шурыгин А.М. Размерности многомерной статистики. // Автоматика и Телемеханика, № 8, 1995.
3. Шурыгин А.М. Регрессия: выбор вида зависимости, эффективность и устойчивость оценок. // Автоматика и Телемеханика, № 6, 1996.
4. Шурыгин А.М. Прикладная стохастика: робастность, оценивание, прогноз. – М.: Финансы и статистика, 2000.
5. Хампель Ф., Рончетти Э., Рауссеу П., Штаэль В. Робастность в статистике. Подход на основе функций влияния. – М.: Мир, 1989.
6. Шакин В.В., Крепец В.В. Робастные нейронные сети и методы регуляризации. // Тезисы докладов IX Всероссийской конференции по Математическим Методам Распознавания Образов (ММРО-9) – М.: ВЦ РАН, 1999.
7. Мешалкин Л.Д. Использование весовой функции при оценке регрессионной зависимости. В сб. Многомерный статистический анализ в социально-экономических исследованиях. – М.: Наука, 1974.
8. Крепец В.В., Белкина Н.В., Скворцов В.С., Петричук С.В., Шакин В.В., Иванов А.С. Программа NNC и ее возможности при построении нейросетевых моделей в биологии и медицине. // Тезисы докладов VII Всероссийской конференции "Нейрокомпьютеры и их применение", – Москва, 2001.
9. Белкина Н.В., Крепец В.В., Шакин В.В. Об устойчивом оценивании параметров нейронных сетей прямого распространения при работе с биологическими объектами. // Автоматика и Телемеханика, № 1, 2002.

10. <http://imgdd.ibmh.msk.su/NNC>

Ассоциативная память на нелинейно-оптических принципах

Б.В. Крыжановский, Л.Б. Литинский
(Москва)

Параметрическая нейронная сеть

В [1] была предложена модель ассоциативной памяти, ориентированная на обработку и хранение информации, закодированной в виде частотно-фазовой модуляции. Одной из целей при этом было – уйти от искусственной адаптации оптической нейросети к амплитудно модулированным сигналам и максимально использовать преимущества, связанные с возможностью передачи сигналов по оптическим межсвязям на q различных частотах $\omega_k, k = 1, \dots, q$. За основу сети был принят *параметрический нейрон* – обладающий кубической нелинейностью элемент, способный к преобразованию и генерации квазимонохроматических импульсов в процессах параметрического четырехволнового смешения $\omega_i - \omega_j + \omega_k \rightarrow \omega_r$. Если отжествить параметрический нейрон с элементарным пикселем экрана, а каждое из q его возможных состояний – с цветом, в который окрашен данный пиксель, то набор одновременных состояний всех N нейронов будет отвечать какому-то цветному изображению на экране.

Память сети локализована в межсвязях, где хранится информация о p *паттернах* - p наперед заданных цветных изображениях. Межсвязи устроены по обобщенному Хеббовскому правилу [2] и легко модифицируются при добавлении новых паттернов.

Сигналы, которыми обмениваются нейроны, преобразуются межсвязями в процессах параметрического четырехволнового смешения. В результате, сеть релаксирует из произвольного начального состояния в ближайшую неподвижную точку. Чтобы вся система работала как ассоциативная память, необходимо, чтобы стартовав из начального состояния, являющегося искажением одного из паттернов, сеть релаксировала именно к этому паттерну. Естественно, хотелось бы, чтобы *области притяжения* паттернов, определяющие допустимый в системе уровень искажений, были как можно больше. Этого удалось добиться за счет выдвинутого в [1] *принципа несоизмеримости частот* как неперемного условия процессов параметрического четырехволнового смешения: *никакая комбинация частот $\omega_i - \omega_j + \omega_k$ не может принадлежать набору $\{\omega_r\}_1^q$, если все три частоты различны*. Именно принцип несоизмеримости частот гарантирует

высокую степень подавления в системе внутренних шумов и обеспечивает паттернам большие области притяжения.

Данная модель ассоциативной памяти получила название *параметрической нейронной сети* (ПНС). Ее дальнейшее исследование пошло по пути создания более универсального языка описания. В частности, удалось разработать матрично-векторный формализм, адекватно передающий все заложенные в модель физические принципы. Это позволило, с одной стороны, уяснить для себя связь ПНС с *векторными нейросетями* типа Поттс-стекольной нейросети [2], а с другой – увидеть ресурс модели и построить новые ее варианты, в том числе – с рекордными на сегодняшний день показателями по емкости памяти и помехоустойчивости. Все математические подробности можно найти в [3].

ПНС-II

В зависимости от способа реализации принципа несоизмеримости (а их возможно несколько), возможны и различные варианты ПНС. Всюду в дальнейшем будем считать, что принцип несоизмеримости реализован в следующей форме: $\omega_i - \omega_j + \omega_k \in \{\omega_r\}^q$ только когда ω_j совпадает с ω_k . Такой вариант принципа несоизмеримости положил начало новой серии моделей - ПНС-II и ПНС-III, - с лучшими, чем в [1] характеристиками. Сформулируем основные результаты для ПНС-II.

Различные состояния параметрического нейрона суть квазимонохроматические импульсы $\kappa(t) = \exp(i(\varpi t + \psi))$, где фаза ψ равна либо 0, либо π , а частота ϖ принимает одно и q значений: $\varpi \in \{\varpi_r\}_1^q$. Состояние сети как целого задается набором одновременных состояний N нейронов: $K = (\kappa_1(t), \kappa_2(t), \dots, \kappa_N(t))$, а p паттернов – это p каких-то, наперед заданных образов:

$$K_\mu = (\kappa_{\mu 1}(t), \kappa_{\mu 2}(t), \dots, \kappa_{\mu N}(t)), \mu = 1, \dots, p.$$

Пусть на вход сети подается искаженный m -й паттерн

$$\hat{K}_m = (a_1 \hat{b}_1 \kappa_{m1}(t), a_2 \hat{b}_2 \kappa_{m2}(t), \dots, a_N \hat{b}_N \kappa_{mN}(t)),$$

где $\{a_i\}^N$ и $\{\hat{b}_i\}^N$ - операторы мультипликативного шума: a_i - независимые случайные величины, принимающие значения -1 и +1 с вероятностями a и $1-a$ соответственно; \hat{b}_i - независимые случайные операторы, с вероятностью b меняющие частоту ϖ_{mi} на какую-то иную, а с вероятностью $1-b$ оставляющие ее неизменной. Иначе говоря, $a \in [0,1]$ характеризует существующий в системе уровень искажений по фазе, а $b \in [0,1]$ - уровень искажений по частоте. Тогда, используя статистическую

технику Чебышева-Чернова [3], вероятность неправильного распознавания m -го паттерна при $N \gg 1$ можно оценить как

$$\text{Pr}_{err} \propto \exp \left[-\frac{Nq^2}{2p} (1-2a)^2 (1-b)^2 \right].$$

Иными словами, вероятность неправильного распознавания экспоненциально затухает с ростом q , а помехозащищенность ПНС-II экспоненциально улучшается.

Емкость памяти α , традиционно измеряемая отношением предельно допустимого числа паттернов к размеру сети, равна

$$\alpha_{\text{ПНС-II}} = \frac{(1-2a)^2}{2} q^2 (1-b)^2.$$

Таким образом, с увеличением q растет и емкость памяти ПНС-II, в q^2 превосходя аналогичный показатель для модели Хопфилда, и в 2 раза – емкость памяти ПНС-I [1] и Поттс-стекольной нейросети [2]. Число паттернов может теперь во много раз превышать число нейронов N – результат, недостижимый для модели Хопфилда.

Мы моделировали работу ПНС-II на компьютере. При числе нейронов $N=100$ и числе различных состояний $q=32$ сеть надежно распознавала любой из 200 паттернов, искаженный не более чем на 90% ($b=0.9$). С увеличением числа паттернов помехоустойчивость сети, естественно, уменьшалась: при $p=2000$ ($\alpha=20$) сеть распознавала паттерны с искажениями до 65%, а при $p=5000$ ($\alpha=50$) – с искажениями до 50%. Заметим, что и для таких, предельно высоких значений α , помехоустойчивость сети можно улучшить, увеличив q до принятого при компьютерной обработке изображений значения $q=256$.

Разработанные модели использовались при создании компьютерно-синтезированных голограмм в ближней зоне дифракции.

Работа выполнена при поддержке гранта РФФИ 01-07-90134 и программы «Интеллектуальные компьютерные системы» (проект 2.45).

Литература

1. Крыжановский Б.В., Микаэлян А.Л. // Доклады АН, сер. мат. физика, 2002, т.383, №3, с318-321.
2. Kanter I. Potts-glass neural network // Physical Review A, 1988, v.37, p.2739-2742.
3. Крыжановский Б.В., Литинский Л.Б. Векторные нейронные сети // Автоматика и Телемеханика, 2003, №10 (в печати).

Непереборный алгоритм отыскания глобального минимума одного функционала

Б.В. Крыжановский, Л.Б. Литинский
(Москва)

Постановка задачи и идея ее решения

1°. В теории нейронных сетей, в физических рассуждениях и при решении различных оптимизационных задач [1], [2] нередко возникает задача отыскания глобального минимума симметричной квадратичной формы N бинарных переменных s_i :

$$\min_{\vec{s}} \left\{ E(\vec{s}) = -(\mathbf{J}\vec{s}, \vec{s}) = -\sum_{i,j=1}^N J_{ij}s_i s_j \right\}, J_{ij} = J_{ji}, s_i = \pm 1. \quad (1)$$

Векторы с бинарными координатами $\vec{s} = (s_1, s_2, \dots, s_N)$ - мы будем называть их *конфигурационными*, - описывают различные состояния системы из N бинарных «агентов» (спинов, нейронов и т.д.), а квадратичную форму $E(\vec{s})$ с симметричной матрицей связей $\mathbf{J} = (J_{ij})_{i,j=1}^N$ трактуют как *энергию* состояния (*ценовую функция, функцию затрат*) и стремятся минимизировать.

В моделях ассоциативных нейронных сетей Хопфилдова типа, состояние, отвечающее локальному минимуму $E(\vec{s})$, является неподвижной точкой динамической системы

$$s_i(t+1) = \operatorname{sgn} \left(\sum_{j=1}^N J_{ij}s_j(t) \right), \quad (2)$$

в которую система релаксирует за несколько тактов своей эволюции. Глобальный минимум отвечает неподвижной точке с наибольшей *областью притяжения*. Энергетическая поверхность, как правило, многоэкстремальна, а отыскивать глобальный минимум перебором всех 2^N конфигурационных векторов \vec{s} уже при $N > 40$ практически невозможно.

Распространенным методом решения подобных задач является *моделирование отжига*, использующее известный алгоритм Метрополиса [3]. Соответствующая вычислительная процедура весьма затратна по времени и не гарантирует отыскания глобального минимума. Наш подход позволяет надеяться на создание алгоритма с вычислительной сложностью порядка $O(N^3)$.

2°. Главная идея нашего подхода состоит в том, чтобы искать вектор $\bar{\mathbf{s}}^*$, доставляющий функционалу глобальный минимум, среди конфигурационных векторов, ближайших к *наибольшим собственным векторам* матрицы \mathbf{J} – к тем собственным векторам, которые отвечают *наибольшим* собственным значениям матрицы.

В самом деле, симметричная матрица \mathbf{J} обладает полным набором собственных векторов $\bar{\mathbf{f}}^{(i)}$, которые мы будем нумеровать в порядке убывания собственных значений λ_i :

$$\mathbf{J} \cdot \bar{\mathbf{f}}^{(i)} = \lambda_i \bar{\mathbf{f}}^{(i)}, \lambda_1 \geq \lambda_2 \dots \geq \lambda_N, (\bar{\mathbf{f}}^{(i)}, \bar{\mathbf{f}}^{(j)}) = \delta_{ij}, i, j = 1, \dots, N;$$

здесь δ_{ij} - символ Кронекера. Тогда можно записать:

$$E(\bar{\mathbf{s}}) = -\left(\lambda_1 (\bar{\mathbf{s}}, \bar{\mathbf{f}}^{(1)})^2 + \lambda_2 (\bar{\mathbf{s}}, \bar{\mathbf{f}}^{(2)})^2 + \dots + \lambda_N (\bar{\mathbf{s}}, \bar{\mathbf{f}}^{(N)})^2\right). \quad (3)$$

Нетрудно показать, что когда наибольшее собственное значение λ_1 существенно превосходит все остальные собственные значения - $\lambda_1 \gg \lambda_i, i = 2, \dots, N$, - решением задачи (1) будет в точности конфигурационный вектор, ближайший к $\bar{\mathbf{f}}^{(1)}$. Координаты этого конфигурационного вектора найти очень просто – они задаются знаками координат самого вектора $\bar{\mathbf{f}}^{(1)}$:

$$s_i^* = \text{sgn}\left(f_i^{(1)}\right) \forall i \Rightarrow (\bar{\mathbf{s}}^*, \bar{\mathbf{f}}^{(1)}) = \sum_{i=1}^N |f_i^{(1)}| \geq |(\bar{\mathbf{s}}, \bar{\mathbf{f}}^{(1)})| \forall \bar{\mathbf{s}}.$$

Следовательно, в этом случае решение задачи (1) проблем не вызывает.

Сложности начинаются, когда у матрицы \mathbf{J} *несколько* наибольших собственных значений сравнимы по величине. В этом случае приходится анализировать целое множество конфигурационных векторов, ближайших к нескольким наибольшим собственным векторам. Однако, вычислительная сложность этой процедуры оценивается как $O(N^3)$, что вполне приемлемо с точки зрения временных затрат.

Результаты компьютерного моделирования

Мы сгенерировали случайным образом 1500 симметричных матриц \mathbf{J} - по 500 матриц размерностями (15x15), (16x16) и (17x17) соответственно. Внедиагональные элементы независимым и случайным образом выбирались из интервала [-4,+4], а диагональные элементы клались равными 0. Для каждой матрицы, с одной стороны, полным перебором отыскивались все

локальные минимумы функционала (1); а с другой - вычислялись все ее собственные значения и векторы. После этого, для каждого из 7-ми наибольших собственных векторов $\vec{f}^{(1)}, \dots, \vec{f}^{(7)}$ отыскивались 3 ближайших конфигурационных вектора $\vec{s}^{(1)}, \vec{s}^{(2)}, \vec{s}^{(3)}$. Затем, найденные таким образом 21 конфигурационный вектор поочередно использовались в качестве стартовых состояний для динамической системы (2), и фиксировалось – в какой из локальных минимумов система срелаксирует? (Такое множество стартовых конфигурационных векторов было продиктовано только возможностями алгоритма.)

Оказалось, что (усредненная по всему ансамблю из 1500 случайных испытаний) вероятность того, что динамическая система срелаксирует в глобальный минимум, стартовав с одного из 3-х конфигурационных векторов, ближайших к наибольшему собственному вектору, равна **0.8**. А вероятность того, что динамическая система срелаксирует в глобальный минимум, стартовав с одного из конфигурационных векторов, ближайших к 7-ми наибольшим собственным векторам, равна **0.97**.

Таким образом, область притяжения глобального минимума функционала $E(\vec{s})$, с вероятностью, близкой к 1, «накрывается» у нас множеством из 21-го конфигурационного вектора.

Вычислительная сложность всей процедуры (отыскание собственных значений и векторов и определение конечного числа стартовых конфигурационных векторов) не превосходит $O(N^3)$. Таким образом, возникает перспектива создания весьма эффективного метода для решения задачи (1). Никаких ограничений на матрицу \mathbf{J} при этом не накладывается (кроме требования ее симметричности).

Переход к матрицам с размерностями порядка $10^2 - 10^3$, равно как и вопрос о том, *сколько* необходимо взять ближайших конфигурационных векторов, и к *скольким* наибольшим собственным векторам, чтобы гарантированно «накрыть» область притяжения глобального минимума? – составляют предмет наших дальнейших исследований.

Данный подход планируется использовать для оптимизации топологии компьютерно-синтезированных голограмм в ближней зоне дифракции.

Работа выполнена при поддержке РФФИ (гранты 01-07-90134, 01-01-00090) и гранта Президента Российской Федерации НШ-1152-2003-1.

Литература

1. Hertz J., Krogh A., Palmer R. Introduction to the Theory of Neural Computation. Addison-Wesley, 1991.
2. Ежов А.А., Шумский С.А. Нейрокомпьютинг и его приложения в экономике и бизнесе. Москва, МИФИ, 1998.
3. Kirkpatrick S., Gelatt C.D., Vecchi M.P. // Science, 1983, v. 202, p. 671.

Повышение емкости памяти модели Хопфилда

В.М. Крыжановский, Л.Б. Литинский

(Москва)

Постановка задачи

Одна из самых популярных моделей ассоциативной памяти - сеть Хопфилда, - способна хранить и надежно восстанавливать только порядка $p_0 \sim N/\ln N$ рандомизированных N -мерных бинарных *паттернов* (исходных образов). При наличии у паттернов корреляций, объем памяти резко падает. В настоящей работе предлагается простой и эффективный алгоритм, позволяющий восстанавливать большое число коррелированных бинарных паттернов по их искаженным изображениям даже в условиях больших шумов. Для этой цели используется новый тип векторной ассоциативной памяти – *параметрическая нейронная сеть* [1],[2]. Суть подхода состоит в следующем.

Пусть имеется семейство N -мерных бинарных паттернов $\{Y_\mu\}$, ($\mu=1,2,\dots,p$), искаженные изображения которых будут предъявляться для распознавания. Каждому паттерну Y_μ из пространства R^N ставится во взаимно-однозначное соответствие *внутренний образ* X_μ в некоем пространстве \mathcal{H} большей размерности, и затем на семействе $\{X_\mu\}$ строится векторная ассоциативная память типа параметрической нейронной сети (ПНС). Межсвязи ПНС устроены по обобщенному Хеббовскому правилу; в них хранится информация о внутренних образах X_μ . Процесс распознавания происходит в следующем порядке: распознаваемый бинарный вектор $Y \in R^N$, являющийся искажением одного из паттернов Y_μ , отображается в $X \in \mathcal{H}$, и результат отображения предъявляется для распознавания ПНС. После чего производится обратное отображение распознанного образа из \mathcal{H} в исходное N -мерное пространство. Поскольку ПНС обладает исключительно большим объемом памяти и высокой помехоустойчивостью, а процедура отображения из R^N в \mathcal{H} сводит практически на нет корреляции, задача распознавания большого числа коррелированных паттернов решается относительно просто.

Отображение бинарных паттернов

Опишем алгоритм отображения бинарных паттернов $\{Y_\mu\}$ во внутренние образы $\{X_\mu\}$. Пусть имеется N -мерный бинарный вектор $Y=(y_1, y_2, \dots, y_N)$, $y_i \in \{0/1\}$. Мысленно разделим его на n фрагментов, содержащих по $m+1$ элементов каждый, $N=n(m+1)$, и уберем запятые между координатами. Каждый фрагмент можно рассматривать как записанное в двоичном коде целое число $\pm k$, если условиться, что первый элемент фрагмента определяет знак числа (0 - знак "минус", 1 - "плюс"), а остальные m элементов – величину целого числа $k \leq q = 2^m$. Поставим теперь каждому фрагменту в

соответствие вектор \mathbf{x} из пространства R^q ($q = 2^m$) по правилу: $\mathbf{x} = \pm \mathbf{e}_k$, где \mathbf{e}_k - k -й вектор-орт в R^q . Тем самым, всему бинарному вектору $Y \in R^N$ ставится в соответствие набор 2^m -мерных векторов, коллинеарных ортам пространства R^q : $X = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)$.

Например, бинарный вектор $Y = (01001001)$ можно разбить на два фрагмента по четыре элемента (0100) и (1001). Первому фрагменту (это "-4" при наших соглашениях) ставим в соответствие вектор $\mathbf{x}_1 = -\mathbf{e}_4$ в пространстве размерности $q=8$, а второму (это "+1") - вектор $\mathbf{x}_2 = +\mathbf{e}_1$ того же пространства. Соответствующее отображение примет вид $Y \rightarrow X = (-\mathbf{e}_4, +\mathbf{e}_1)$.

Применив эту процедуру последовательно ко всем бинарным паттернам $\{Y_\mu\}$, получим p внутренних образов $\{X_\mu\}$, на основе которых и строится векторная ПНС [1],[2].

Величину m будем называть *параметром отображения*. Существенно, что описанное отображение взаимно однозначно, т.е. по X можно однозначно восстановить его бинарный прообраз Y . Еще более существенно, что с ростом параметра отображения m , во-первых, уменьшается степень коррелированности паттернов (в чем легко убедиться); а, во-вторых, экспоненциально растет размерность 2^m векторов-нейронов ПНС. Совокупное действие этих двух факторов приводит, в конечном итоге, к *экспоненциальному* увеличению числа паттернов, которые могут быть надежно восстановлены по их искаженным изображениям.

Распознающие свойства системы

Приведем оценки емкости памяти для некоррелированных бинарных паттернов. Пусть $Y = (s_1 y_{\mu 1}, s_2 y_{\mu 2}, \dots, s_n y_{\mu n})$ - искаженный μ -й бинарный паттерн, а s_i - оператор мультипликативного шума, с вероятностью s изменяющий значение переменной $y_{\mu i}$ на противоположное, и с вероятностью $1-s$ оставляющий ее неизменной. Иначе говоря, s характеризует уровень искажения паттерна. Как обычно, для бинарных паттернов уровень искажений не превышает 50% - $s \leq 0.5$, - поскольку искажение паттерна *больше* чем на 50% трактуется системой как искажение «негатива» паттерна (его зеркального отражения) *меньше* чем на 50%, и приводит к тем же результатам.

Для вероятности ошибки распознавания μ -го паттерна имеет место оценка:

$$P_{err} \leq n \exp \left\{ -\frac{n(1-2s)^2}{2p} [2(1-s)]^{2m} \right\} \quad (1)$$

Предельно допустимое число паттернов, для которого при $N \rightarrow \infty$ вероятность ошибки распознавания стремится к 0, дается выражением:

$$\bar{p} = \frac{n(1-2s)^2}{2 \ln n} [2(1-s)]^{2m} \quad (2)$$

При $m=0$ эти оценки переходят в известные результаты для модели Хопфилда, а число распознаваемых паттернов \bar{p} становится равным p_0 . Поскольку $2(1-s) \geq 1$, с ростом m имеется как стремительное уменьшение вероятности ошибки распознавания (1), так и экспоненциальный рост числа распознаваемых паттернов (2).

При наличии у исходных бинарных паттернов корреляций, объем нейросетевой памяти несколько ниже оценки (2), однако и в этом случае, с ростом параметра отображения m имеет место экспоненциальный рост емкости памяти и уменьшение ошибки распознавания.

В целом, предложенная схема весьма проста в реализации и эффективна. Она может успешно использоваться и для иных нейросетевых архитектур. Например, однослойный векторный персептрон, выходные нейроны которого кодируют номер распознаваемого паттерна, может быть использован как схема быстрого поиска. При искажениях распознаваемых паттернов свыше 20% скорость работы такого поискового алгоритма на порядок превышает скорость работы стэкового алгоритма быстрого поиска.

Работа выполнена при поддержке РФФИ (гранты 03-01-00355 и 01-07-90308).

Литература

1. Крыжановский Б.В., Микаэлян А.Л.// Доклады АН, сер. мат.физика, 2002, т.383, №3, с318-321.
2. Крыжановский Б.В., Литинский Л.Б. Векторные нейронные сети // Автоматика и Телемеханика, 2003, №10 (в печати).

Предварительная обработка данных в процессе их аналитического описания с помощью ортогональных рядов

Л.И. Куликова

(г. Пушкино)

Фильтрация помех

Очень часто исследователи сталкиваются с трудностями, когда по каким-либо причинам не удается получить «чистые» экспериментальные данные; так как результаты экспериментальных исследований представляют собой, как правило, сигналы, зашумленные высокочастотными помехами. Поэтому непосредственное их использование затрудняет получение с требуемой точностью различных оценок и характеристик. Следовательно, прежде чем приступить к обработке полученных в ходе эксперимента данных, приходится решать задачу – что есть шум, а что является «чистыми»

выходными данными научного эксперимента; и, определив, необходимо избавиться от шума. Предлагаемая методика аналитического описания данных экспериментов [1,2,3], основанная на разложении зашумленных сигналов в ортогональные ряды на базе использования классических ортогональных базисов, решает задачу сглаживания высокочастотных помех. Такое достаточно легкое и красивое решение проблемы получается благодаря замечательным свойствам классических ортогональных базисов, обладающих повышенным эффектом сглаживания искажений в результате свертки входного сигнала $x(t)$ с базисными функциями $\varphi_n(t)$ (вычисления коэффициентов разложения A_n). Процедура сводится к вычислению известного интеграла Фурье:

$$A_n = \int_0^T x(t) \cdot \varphi_n(t) \cdot \rho(t) dt, \quad (1)$$

$\rho(t)$ - весовая функция данного базиса.

Подбором ортогонального базиса с соответствующей весовой функцией удается существенно снизить влияние помех на точность вычисления коэффициентов A_n и аналитическое описание.

Вычисление производных

Особенно серьезные затруднения возникают при вычислении производных от зашумленных сигналов, знание которых необходимо при решении целого ряда задач. Существует ряд алгоритмов и программ решения данной задачи цифровыми методами, используя которые, можно получить первую производную. Но вычисление даже второй производной с требуемой точностью становится очень проблематичным. В этом случае нет альтернативы использованию спектрального подхода.

Более того, создан банк формул [4] пересчета коэффициентов A_n , используя который можно вычислять коэффициенты разложения для производных, по которым восстанавливаются первая, вторая и последующие производные с требуемой точностью. Исходя из конкретных условий, можно практически всегда подобрать такой ортогональный базис, который обеспечит бы заданную точность описания сигнала и его производных при разумно малых объемах вычислений.

На рисунке 1 показаны кривая, полученная в эксперименте, и ее аналитическое описание с использованием ортогональных полиномов Лежандра $[0, T]$ (глубина аппроксимации равна 14). На рисунке 2 приводится результат вычисления первой и второй производных экспериментальной кривой через коэффициенты разложения и точная первая производная той же кривой, предварительно сглаженной многократным применением «скользящего фильтра». Но даже после такой предварительной обработки

данных вторая производная (не представлена на рисунке) вычисляется с неудовлетворительной точностью.

]. Выполняемые исследования поддержаны РФФИ (проекты 01-02-16127, 01-07-90317, 00-01-05000), проектом 107 6-го конкурса молодых ученых РАН.

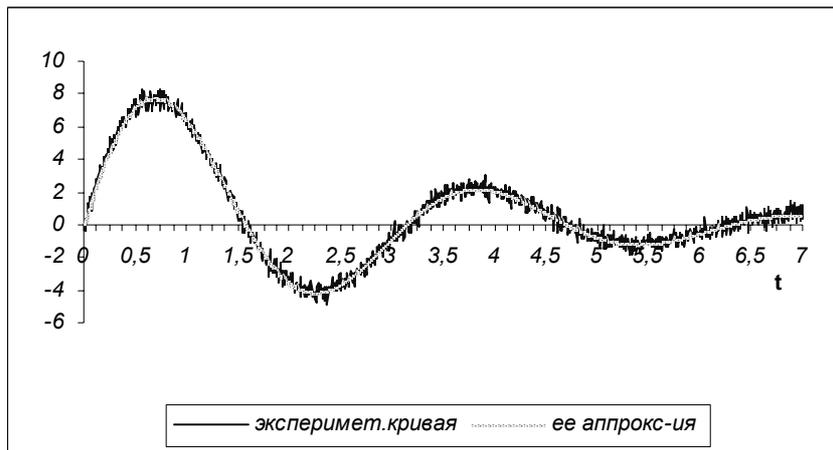


Рис.1.

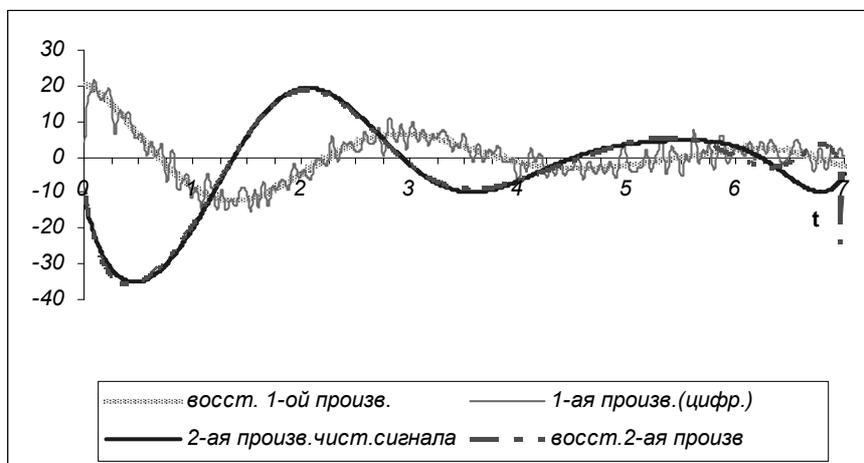


Рис.2.

Литература

1. Дедус Ф.Ф. Аналитическое представление экспериментальных данных и их обработка. Кибернетика и вычислительная техника. Вып.74, «Наукова думка», Киев, 1987.

2. Дедус Ф.Ф. Комбинированные цифро-аналитические методы обработки данных экспериментов. Материалы III международной школы по автоматизации научных исследований. Пущино, 1990, с.52-77.
3. Дедус Ф.Ф., Махортых С.А., Устинин М.Н., Дедус А.Ф. Обобщенный спектрально – аналитический метод обработки информационных массивов. Задачи анализа изображений и распознавания образов. // М.: «Машиностроение», 1999, 357с., ил.
4. Куликова Л.И., Дедус Ф.Ф., Махортых С.А. Обобщенный спектрально – аналитический метод в задачах обработки экспериментальных данных. // Горизонты биофизики. От теории к практике. Пущино, 2003, с.56-62.

**Исследование зависимости критерия качества
прогнозирования многомерной переменной от объема
выборки и сложности решающей функции**

Г.С. Лбов, Т.А. Ступина

(Новосибирск)

В данной работе рассматривается один из подходов решения проблемы статистической устойчивости решающих функций прогнозирования многомерной разнотипной переменной к объему выборки. Отметим, что задачи распознавания образов и регрессионного анализа являются частными случаями рассматриваемой задачи, для которых вопрос устойчивости в основном был исследован в работах В.Н. Вапника, А.Я. Червоненкиса, Ш.Ю. Раудиса, Н.Г. Старцевой и др. [1,2,3,4].

Задача прогнозирования многомерной разнотипной переменной впервые была сформулирована в работах [5,6], однако вопросы зависимости качества решения от объема выборки и сложности решающей функции для данной задачи не были исследованы. В данной работе методом статистического моделирования для определенных значений объема выборки и сложности решающей функции получены оценки качества решения, ниже приводятся результаты такого моделирования.

Задача прогноза многомерной переменной состоит в том, чтобы для произвольного объекта a из генеральной совокупности Γ по известным значениям переменных X_1, X_2, \dots, X_n (описании объекта) предсказать значения целевых (прогнозируемых) переменных Y_1, Y_2, \dots, Y_m на основе анализа имеющейся эмпирической информации (таблицы данных).

Рассматриваются два пространства $D_X = \prod_{j=1}^{def} D_{X_j}$, $D_Y = \prod_{j=1}^{def} D_{Y_j}$,

где D_{X_j}, D_{Y_j} - множества допустимых значений переменных X_j и Y_j соответственно.

Отображение f , ставящее в соответствие каждому набору значений $x \in D_X$ некоторую многомерную целевую переменную $y \in D_Y$, назовем решающей функцией, $f \in \Phi$, где Φ - заданный класс решающих функций.

В данной работе будем полагать, что решающая функция из класса логических решающих функций, $f \in \Phi_M$ [6], где M - параметр, определяющий сложность логической решающей функции (число конечных вершин дихотомического дерева при заданном типе предиката в узлах дерева). Обоснование такому выбору приведено в работе [7].

Качество $F(c, f)$ решающей функции при фиксированной стратегии природы c , $c = \{p(x, y) = p(x)p(y/x), x \in D_X, y \in D_Y\}$ определяется следующим образом. Введем критерий $K(\alpha)$ качества разбиения α . Если стратегия природы c известна, то для любого разбиения α можно определить условное распределение $P(y|x)$. Обозначим через $p_{x,y}^t = P(x \in E_X^t, y \in E_Y^t)$ совместную вероятность попадания x в E_X^t и y в E_Y^t , и аналогично $p_{y|x}^t = P(y \in E_Y^t | x \in E_X^t)$, $p_x^t = P(x \in E_X^t)$, $p_y^t = P(y \in E_Y^t)$, где $E_X^t \in \alpha$, $E_Y^t \in \beta$. Тогда

$$F(c, f) = 1 - K(\alpha) = 1 - \sum_{t=1}^M \rho^t p_x^t, \text{ где } \rho^t = \max_{E_Y^t \in \beta} (p_{y|x}^t - p_y^t) \text{ [7].}$$

Для фиксированной стратегии природы c определим оптимальную решающую функцию $f_0(x)$ как такую, для которой выполняется: $F(c, f_0) = \inf_{f \in \Phi_0} F(c, f)$, где Φ_0 - класс решающих функций.

Стратегия природы, как правило, неизвестна, поэтому решающая функция строится по обучающей выборке $V = (x^i, y^i)_{i=1, \dots, N}$ с помощью некоторого алгоритма $Q(V) = \bar{f}$, где $\bar{f}(x)$ выборочная решающая функция, N - объем обучающей выборки. В этом случае получаем уровень ошибки больший, чем при принятии решения $f_0(x)$, т.е. $F_N(c, \bar{f}) \geq F(c, f_0)$.

Множество решающих функций, продуцируемых алгоритмом $Q(V)$

образуют класс Φ . Качество алгоритма Q определяется математическим ожиданием критерия $EF_N(c, \bar{f})$, полученного путем усреднения по всевозможным выборкам объема N , $\bar{f} \in \Phi$.

Мера адекватности класса решающих функций Φ стратегии c есть $\gamma(c) = F(c, f^*) - F(c, f_0)$, где $f^* \in \Phi$, $F(c, f^*) = \inf_{f \in \Phi} F(c, f)$.

Чем больше γ , тем больше несоответствие (неадекватность) между стратегией природы и рассматриваемым классом Φ .

Мера устойчивости алгоритма Q к объему выборки N есть величина $\kappa(c, N) = EF_N(c, \bar{f}) - F(c, f^*)$, $\bar{f}, f^* \in \Phi$.

Мера устойчивости определяет эффект ограниченности объема выборки: с уменьшением объема величина $\kappa(c, N)$ возрастает (устойчивость уменьшается), с увеличением N величина $\kappa(c, N) \rightarrow 0$. Таким образом, математическое ожидание критерия качества алгоритма Q для фиксированных c, Φ, N определяется следующим выражением:

$EF_N(c, \bar{f}) = F(c, f_0) + \gamma(c) + \kappa(c, N)$, где значение $F(c, f_0)$ определяет информативность переменных X_1, \dots, X_n и является константой.

Методом статистического моделирования исследована зависимость $EF_N(c, \bar{f})$ от объема выборки ($12 \leq N \leq 32$) и сложности ($M^* = 3, 4, 5$ при истинной сложности $M = 5$) для $n = 3$ и $m = 2$. Так, например, $EF_{30}(c, \bar{f})$ при $M^* = 4$ меньше, чем $EF_{30}(c, \bar{f})$ при $M^* = 5$, а при объеме выборки меньшем 23 величина $EF_N(c, \bar{f})$ принимает наименьшее значение при $M^* = 3$.

Работа выполнена при поддержке РФФИ, 01-01-00839

Литература

1. Вапник В.Н., Червоненкис А.Я., Теория распознавания образов.// Москва: Наука, 1970
2. Вапник В.Н., Восстановление зависимостей по эмпирическим данным.// Москва: Наука, 1979
3. Раудис Ш.Ю., Ограниченность выборки в задачах классификации.// Статистические проблемы управления, Вильнюс. Институт математики и кибернетики, 1976. Вып. 18, с.1-185
4. Старцева Н.Г., Оценка сходимости математического ожидания

- вероятности ошибки классификации для усредненной стратегии.// Д.А.Н, 1995, т. 341, №5, с.606-609
5. Лбов Г.С., Неделько В.М. Восстановление условного распределения на основе экспериментальных данных.// "Информатика и процессы управления". Межвузовский сборник. КГТУ, Красноярск, 1997г. с.54-61
 6. Лбов Г.С., Старцева Н.Г. Логические решающие функции и вопросы статистической устойчивости решений.// Новосибирск: Изд-во Ин-та математики, 1999, 212с
 7. Лбов Г.С., Ступина Т.А. О критерии качества решающей функции при прогнозировании многомерной переменной.// "Искусственный интеллект 2'2002" Труды международной конференции, Алушта, 2002, с.172-179

Оценка параметров вращений трехмерного группового точечного объекта без предварительной нумерации

формирующих точек

А.Н. Леухин, Д.Г. Хафизов

(Йошкар-Ола)

1. Постановка задачи

Совокупность S точек

$$\Xi = \{\xi(n)\}_{0,s-1} = \{(q_1(n); q_2(n); q_3(n))\}_{0,s-1} \quad (1)$$

в трехмерном пространстве будем рассматривать как групповой точечный объект (ГТО). Здесь $q_1(n)$, $q_2(n)$, $q_3(n)$ - координаты n -ой точки в трехмерной декартовой системе координат, $n = 0, 1, \dots, s-1$.

Координаты n -ой точки в декартовой системе координат задают n -ый векторный кватернион

$$q(n) = q_1(n) \cdot i + q_2(n) \cdot j + q_3(n) \cdot k, \quad (2)$$

где i , j и k - мнимые единицы кватерниона. Тогда для аналитического описания ГТО сформируем кватернионный сигнал (КТС) [1], упорядочив множество кватернионов, соответствующих каждой точке из множества Ξ

$$\mathbf{Q} = \{q(n)\}_{0,s-1} = \{q_1(n) \cdot i + q_2(n) \cdot j + q_3(n) \cdot k\}_{0,s-1}, \quad (3)$$

КТС $\mathbf{P} = \{p(n)\}_{0,s-1}$ образован в результате вращения исходного КТС

\mathbf{Q} . КТС $\mathbf{N} = \{v(n)\}_{0,s-1}$ образован в результате произвольной перестановки векторных кватернионов в составе повернутого КТС \mathbf{P} .

При распознавании и оценке параметров изображений зашумленных ГТО существует сложная проблема идентификации (нумерации) точек входящих

в состав этого ГТО. Данный доклад посвящен решению задачи оценки параметров без предварительной нумерации точек. Предлагаемый алгоритм является развитием метода предложенного в работах [2,3].

2. Алгоритм оценки параметров вращения

Определим параметры вращающего кватерниона

$$\begin{aligned} b &= \cos \varphi + r \sin \varphi = b_0 + b_1 i + b_2 j + b_3 k = \\ &= \cos \varphi + (r_1 i + r_2 j + r_3 k) \sin \varphi, \end{aligned} \quad (4)$$

где $\|b\| = \sqrt{b_0^2 + b_1^2 + b_2^2 + b_3^2} = 1$, $\|r\| = \sqrt{r_1^2 + r_2^2 + r_3^2} = 1$, 2φ - угол поворота вокруг оси, задаваемой координатами b_1, b_2 и b_3 . Для оценки параметров вращающего кватерниона b приведем следующий алгоритм.

1. Определим нормированные кватернионы g_Q и g_N , координаты которых задаются центрами тяжести исходного КТС Q и повернутого КТС N с измененной нумерацией векторов в его составе:

$$\begin{aligned} g_Q &= \frac{\sum_{n=0}^{s-1} q_1(n) \cdot i + \sum_{n=0}^{s-1} q_2(n) \cdot j + \sum_{n=0}^{s-1} q_3(n) \cdot k}{\sqrt{\left(\sum_{n=0}^{s-1} q_1(n)\right)^2 + \left(\sum_{n=0}^{s-1} q_2(n)\right)^2 + \left(\sum_{n=0}^{s-1} q_3(n)\right)^2}}, \quad (5) \\ g_N &= \frac{\sum_{n=0}^{s-1} v_1(n) \cdot i + \sum_{n=0}^{s-1} v_2(n) \cdot j + \sum_{n=0}^{s-1} v_3(n) \cdot k}{\sqrt{\left(\sum_{n=0}^{s-1} v_1(n)\right)^2 + \left(\sum_{n=0}^{s-1} v_2(n)\right)^2 + \left(\sum_{n=0}^{s-1} v_3(n)\right)^2}}. \end{aligned}$$

2. Вычислим параметры вращающих кватернионов $b_Q = b_{Q0} + b_{Q1}i + b_{Q2}j + b_{Q3}k$ и $b_N = b_{N0} + b_{N1}i + b_{N2}j + b_{N3}k$, совмещающих кватернионы g_Q и g_N с осью OZ (мнимой единицей k):

$$\begin{aligned} b_Q &= \cos \varphi_Q + \frac{\sin 2\varphi_Q}{\sin \varphi_Q} \cdot (g_{Q2} \cdot i - g_{Q1}j), \quad (6) \\ b_N &= \cos \varphi_N + \frac{\sin 2\varphi_N}{\sin \varphi_N} \cdot (g_{N2} \cdot i - g_{N1}j), \end{aligned}$$

где $2\varphi_Q = \arccos g_{Q3}$, $2\varphi_N = \arccos g_{N3}$ - углы поворотов для

совмещения кватернионов g_Q и g_N с осью OZ .

3. Выполним поворот кватернионных сигналов Q и N :

$$Q_z = b_Q \cdot Q \cdot b_Q^{-1}, \quad N_z = b_N \cdot N \cdot b_N^{-1}. \quad (7)$$

4. Обозначим угол поворота кватернионного сигнала Q_z вокруг оси OZ для получения сигнала N_z через 2δ . Вращающий кватернион

$$b_z = \cos \delta - \sin \delta \cdot k, \quad (8)$$

где
$$2 \cdot \delta = \arg \left(\frac{\gamma_{l, m_{N_z}}}{\gamma_{l, m_{Q_z}}} \right) / m, \quad m = -l, \dots, -1, 1, \dots, l, \quad (9)$$

где
$$\gamma_{lm\phi} = \sqrt{\frac{(2l+1)(l-m)!}{4\pi(l+m)!}} \cdot \sum_{n=0}^{s-1} P_l^m(\cos \theta(n)) \cdot e^{-im\phi(n)} \sin \theta(n) =$$

$$= \sum_{n=0}^{s-1} Y_m^l(\theta(n), \phi(n))^* \cdot \sin \theta(n), \quad (10)$$

коэффициент спектрального разложения сферической функции $\Phi(\theta, \varphi)$, ассоциированной с КТС Q ; $Y_m^l(\theta(n), \varphi(n))$ - сферическая гармоника степени l и порядка m ; $P_l^m(\cos(\theta(n)))$ - присоединенные полиномы Лежандра первого рода; $\theta(n)$, $\varphi(n)$ - сферические координаты n -го векторного кватерниона в составе КТС Q .

5. На основании свойства суммы поворотов искомым вращающий кватернион определится как:

$$b = -b_N^* \cdot b_z \cdot b_Q = b_0 + b_1 \cdot i + b_2 \cdot j + b_3 \cdot k, \quad (11)$$

где
$$b_0 = b_{N_1} \cdot b_{z_3} \cdot b_{Q_2} - b_{N_2} \cdot b_{z_0} \cdot b_{Q_2} - b_{N_2} \cdot b_{z_3} \cdot b_{Q_1} -$$

$$- b_{N_1} \cdot b_{z_0} \cdot b_{Q_1} - b_{N_0} \cdot b_{z_0} \cdot b_{Q_0},$$

$$b_1 = b_{N_0} \cdot b_{z_3} \cdot b_{Q_2} - b_{N_0} \cdot b_{z_0} \cdot b_{Q_1} + b_{N_1} \cdot b_{z_0} \cdot b_{Q_0} + b_{N_2} \cdot b_{z_3} \cdot b_{Q_0},$$

$$b_2 = b_{N_2} \cdot b_{z_0} \cdot b_{Q_0} - b_{N_1} \cdot b_{z_3} \cdot b_{Q_0} - b_{N_0} \cdot b_{z_3} \cdot b_{Q_1} - b_{N_0} \cdot b_{z_0} \cdot b_{Q_2},$$

$$b_3 = -b_{N_2} \cdot b_{z_0} \cdot b_{Q_1} + b_{N_1} \cdot b_{z_0} \cdot b_{Q_2} + b_{N_1} \cdot b_{z_3} \cdot b_{Q_1} -$$

$$- b_{N_0} \cdot b_{z_3} \cdot b_{Q_0} + b_{N_2} \cdot b_{z_3} \cdot b_{Q_2}.$$

3. Выводы

В работе предлагается алгоритм оценки параметров вращений

неупорядоченных ГТО на основе спектрального разложения ассоциированных с КТС сферических функций в базисе сферических гармоник.

Работа поддержана грантом РФФИ 01-01-00298.

Литература

1. Введение в контурный анализ и его приложения к обработке изображений и сигналов/ Я.А.Фурман, А.В.Кревецкий, А.К.Передреев, А.А. Роженцов, Р.Г.Хафизов, И.Л.Егошина, А.Н.Леухин. – М.: Физматлит, 2002. – 592 с.
2. А.Н. Леухин. Оценка параметров вращений кватернионных сигналов на основе сферического спектрального анализа. //Труды 6-ой Межд. конференции РОАИ-6-2002, Том.1. – В.Новгород, 2002. – с.352-356.
3. A.N.Leukhin. Parameter Estimation of Quaternion Signal Rotation on the Base of Spherical Analysis. – Patt. Rec. and Im. Anal., Vol.13, No.1, 2003.

Задачи различения

А.В. Марусяк, Ю.Л. Шередеко

(Киев)

Новый подход к обобщению методов решения задач различения

К задачам различения относятся задачи идентификации и распознавания образов. В большинстве случаев под задачей идентификации подразумевают классическую задачу распознавания, т.е. отнесение объекта к одному из N известных классов, где $N \geq 2$. В [1] показано, что задача распознавания образов есть частный и вырожденный случай задачи идентификации, так как задача идентификации состоит в различении объектов среди $N+M$ классов, где: $N \geq 1$ - количество известных классов; $M \in \{0, \infty\}$ - количество неизвестных классов.

Любое различение опирается на некоторую совокупность признаков – алфавит признаков, а нахождение этого алфавита составляет задачу обучения различению. Множество всех возможных классов различаемых объектов составляет алфавит классов. В случае задачи распознавания алфавит классов N конечен и известен, а в случае идентификации алфавит классов $N+M$ не известен и, в общем случае, открыт ($M \rightarrow \infty$).

Классификация задач различения приведена в таблице 1.

Таблица 1. Классификация задач различения.

		Алфавит признаков	
		Известен	Не известен
Алфавит классов	Известен	Распознавание образов	Обучение распознаванию образов
	Не известен	Идентификация	Обучение идентификации

Рассмотрим кратко каждую из этих задач:

1). В случае, когда известен и алфавит классов и алфавит признаков – решается классическая *задача распознавания образов* – отнесение объекта к одному из N известных классов. При этом нет необходимости сравнения описания объекта с каждым из N известных классов, достаточно организовать *иерархический поиск* по значениям признаков и, таким образом, избежать полного перебора.

2). В случае, когда алфавит классов не известен, а алфавит признаков априорно задан (известен), то решается задача идентификации, в которой кроме отнесения объекта к одному из N известных классов, необходимо еще выяснить, относится ли вообще этот объект к известным. Обычно это выясняют путем полного перебора - сравнения полного описания объекта с *каждым* из N известных классов по следующим правилам:

- если описание не совпало ни с одним из N – объект относится к неизвестным;
- если описание совпало с единственным из N – объект относится к этому классу;
- если описание совпало более чем с одним из N – ситуация неопределенности.

Такой метод решения задачи идентификации очень трудоемок и при больших N (например, в существующих базах отпечатков пальцев N достигает $10^8 \div 10^9$) требует применения дорогих вычислительных систем и/или введения априорных ограничений области поиска. В [1] предложена двухстадийная схема идентификации, которая дает возможность *сначала* определить, относится данный объект к N известным, или к M неизвестным классам, и если относится – решать задачу распознавания образов. Это позволяет использовать преимущества распознавания для организации иерархического поиска, что существенно (на много порядков) снижает трудоемкость решения при больших N .

3). В случае, когда алфавит классов известен, а алфавит признаков не известен – решается задача обучения распознаванию образов: нахождение совокупности наиболее эффективных признаков, которые позволят отнести объект к одному из N известных классов. Необходимое условие решения данной задачи – наличие представительной выборки объектов *каждого* из N известных классов. По сути, эта хорошо изученная задача сводится к нахождению *различий* объектов известных классов, что не представляет принципиальных трудностей.

4). В задаче обучения идентификации, - случай, когда не известны оба алфавита – возникают трудности принципиального порядка: существует M классов, для которых *нет обучающих выборок* (очевидно, что искать различия объектов, которых нет, невозможно). По этой причине использование методов обучения распознаванию образов для решения этой задачи считается проблематичным и задача обучения идентификации

(нахождение алфавита признаков при открытом алфавите классов) не только не решается, - даже не ставится и не исследуется. Сказанное подтверждается практикой: все существующие системы идентификации человека по биометрическим показателям основаны на использовании априорных алфавитов признаков, получаемых из опыта и/или интуитивно, но без постановки и решения задачи обучения идентификации.

Предложенная в [1] двухстадийная схема идентификации позволяет свести задачу обучения идентификации к задаче обучения распознаванию образов. Задача обучения возникает, если на первой стадии идентификации предъявленный объект опознан как *новый*, относящийся к неизвестным классам. Поскольку данный объект является *представителем* одного из неизвестных классов, то можно поставить задачу поиска отличий этого объекта от объектов известных классов, причем эта задача ничем не отличается от классической задачи обучения распознаванию образов.

Таким образом, вся сложность сведения задач идентификации и обучения идентификации к задачам распознавания и обучения распознаванию образов заключается в первой стадии предложенной схемы идентификации, которая может показаться несколько фантастичной. В самом деле, на первый взгляд непонятно как можно *опознать неизвестное*, как еще до сравнения с каждым из N известных классов определить, что рассматриваемый объект принадлежит к M неизвестным. Идея первой стадии заключается в использовании запрещений - сочетаний значений признаков, которые не встречаются среди N известных классов, т.е. обозначают классы, содержащие неизвестные системе идентификации объекты. Список запрещений конечен (это следует из конечности набора используемых признаков) и сформирован заранее, до очередного акта идентификации, потому иерархический поиск совпадений описания предъявленного объекта с запрещениями реализуется также как поиск в системах распознавания.

К осознанию отличий задачи обучения идентификации от задачи обучения распознавания образов и построению двухстадийной схемы идентификации авторов привела работа над созданием системы идентификации по электрокардиосигналу. В существующих системах идентификации по биометрическим показателям (отпечатки пальцев, сетчатка и радужная оболочка глаза, геометрия лица и руки, её отпечаток, рисунок кровеносных сосудов руки, подпись и т.д.) алфавит признаков априорно задается человеком, т.е. человек может произвести идентификацию без соответствующей компьютерной системы и проводил её "вручную" до создания этой системы. В отличие от этих систем в задачи идентификации по электрокардиосигналу человек не может произвести идентификацию "вручную", без создания соответствующей компьютерной системы.

Следует отметить, что предложенный подход имеет самостоятельное

значение вне зависимости от его связи с задачей идентификации по электрокардиосигналу. Подобным же образом могут быть созданы системы идентификации и по другим биометрическим свойствам человека, например, по голосу, почерку и т.п. Предлагаемый подход может найти применение и в решении познавательных задач, например, для автоматизации поиска симптомов болезней по электрокардиосигналу.

Реализация предлагаемого подхода способна значительно повысить эффективность создаваемых систем идентификации, особенно при работе с большим количеством известных классов. А главное предлагаемый подход открывает путь к постановке и решению задач нового класса - обучения идентификации.

Литература

1. Шередеко Ю.Л., Марусяк А.В. Способ корректного сведения задачи идентификации к задаче распознавания образов // УСиМ. – 2002. – №5. – с.5-12.

Коррекция данных в задаче классификации *В.Л. Матросов, В.А. Горелик, С.А. Жданов, О.В. Муравьева* (Москва)

Рассматривается геометрический подход к задаче распознавания образов. Пусть задан набор объектов в m -мерном пространстве признаков. Требуется определить разрешающее правило, разделяющее множество точек на два класса. Данная задача в силу разных причин может не иметь решение для разделяющих кривых определенного типа. Формулируется задача минимальной в каком-либо смысле коррекции координат заданных точек (значений признаков), в результате которой существует функция от m -мерного вектора, обладающая заданными свойствами на скорректированных объектах.

Пусть требуется определить линейное разрешающее правило, т.е. построить в пространстве признаков разделяющую гиперплоскость. Алгебраически коэффициенты искомой линейной функции задаются системой линейных неравенств, матрица коэффициентов которой состоит из координат заданных объектов. В этом случае задача минимальной коррекции данных по критерию, зависящему от величины возмущений всех значений признаков, представляет собой задачу коррекции несовместной системы линейных неравенств. Используя методы, предложенные в [1]–[3], можно показать, что такая задача сводится к задаче линейного программирования в случае минимаксного критерия (максимального значения отклонения) и задачам квадратичного программирования в случае квадратичного критерия (суммы квадратов отклонений).

Литература

1. Горелик В.А. Матричная коррекция задачи линейного программирования с несовместной системой ограничений. // ЖВМиМФ, 2001. Т.41, №11. С.1697–1705.
2. Горелик В.А., Ибатуллин Р.Р. Коррекция системы ограничений задачи линейного программирования с минимаксным критерием. // Моделирование, декомпозиция и оптимизация сложных динамических процессов. М.: ВЦ РАН, 2001. С.89–107.
3. Матросов В.Л., Горелик В.А., Муравьева О.В. Методы коррекции и аппроксимации несобственных задач линейного программирования и их приложения. // Научные труды Московского педагогического государственного университета. Серия: Естественные науки. М.: Прометей, 2002.

Синтез алгоритма с заданным качеством

В.Л. Матросов, Е.А. Иванова, С.А. Жданов

(Москва)

Из результатов работы [1] следует, что длина обучающей выборки q , достаточная для построения алгоритма с заданным качеством ε , может быть оценена следующим образом: $q \geq \Delta f(n, \eta, \varepsilon)$, где функция f имеет различные представления в зависимости от того, какой случай рассматривается: стохастический или детерминистский.

В детерминистском случае для всякой $Z \in \tilde{Z}(m, q)$ в данной модели $U_P^L \{M\}$ существует алгоритм, безошибочно решающий задачу Z , и тогда $f(n, \eta, \varepsilon) = 4/\varepsilon (1 - \ln \varepsilon/4 - \ln \eta/3)$, а в стохастическом случае существование такого алгоритма, вообще говоря, неизвестно, но для всякой задачи Z существует алгоритм, решающий Z с достаточно малым количеством ошибок (удовлетворяющим некоторому порогу качества), и в этом случае

$$f(n, \eta, \varepsilon) = \frac{1}{2} \varepsilon^2 (1 - (\ln \eta/5 - \varepsilon^2/2)/\Delta - \ln(\varepsilon^2/2)).$$

В обоих случаях важно подчеркнуть одно свойство данной функции f – она монотонно возрастает по каждому из аргументов $n, \eta^{-1}, \varepsilon^{-1}$.

Наш основной результат может быть сформулирован следующим образом.

Теорема. Для всяких $\eta, \varepsilon > 0$ с вероятностью $1 - \eta$ частота ошибок алгоритма из $U_P^L \{M\}$, решающего контрольную выборку \tilde{S}^q , отличается от частоты ошибок данного алгоритма на обучающей выборке не более чем на ε , если величина отношения длины выборки q к произведению параметров модели $U_P^L \{M\}$ удовлетворяет условию

$$q(2w(\epsilon t + L)(\log(mL + 1) + 1))^{-1} \geq f(n, \eta, \epsilon),$$

где $w \leq n$; $\epsilon t < L$.

Настоящая теорема указывает на возможность синтеза алгоритма с заданным качеством для всякой регулярной задачи, имеющей относительно невысокую размерность алгоритма, корректного на ее обучающей выборке.

Литература

1. Вапник В. Н., Червоненкис А. Я. Теория распознавания образов. М.: Наука, 1979. 448 с.

Беспереборная минимизация числа аргументов в задаче восстановления линейной регрессионной зависимости по малым обучающим выборкам

В.В. Моттль, О.В. Красоткина
(Москва, Тула)

Введение

Для практики анализа данных типична необходимость восстановления линейной регрессионной зависимости $y \cong \psi(\omega) = \sum_{i \in A} x_i z_i(\omega)$ в некотором множестве объектов $\omega \in \Omega$, характеризуемых совокупностью A их числовых признаков $z_i(\omega)$, по обучающей выборке $\{(y_t, \omega_t); t = 1, \dots, N\}$. Как правило, число признаков $n = |A|$, которые могут быть измерены на объектах, превосходит число доступных наблюдений N . Требуется, анализируя малую обучающую выборку, отобрать некоторое подмножество наиболее информативных признаков (активных регрессоров) $\hat{A} \subset A$ и найти коэффициенты линейной модели по этим признакам $\hat{\psi}(\omega) = \sum_{i \in \hat{A}} x_i z_i(\omega)$ так, чтобы обеспечить как можно меньшую среднюю ошибку предсказания выхода для новых объектов $\omega \in \Omega$, не участвовавших в обучении.

Существует множество критериев отбора регрессоров в процессе обучения, среди которых наиболее широкое применение нашли информационный критерий Акаике [1] и методы, основанные на дисперсионном анализе [1]. Однако каков бы ни был критерий, позволяющий сравнивать разные подмножества в множестве регрессоров, выбор наилучшего подмножества всегда связан с огромным перебором, обуславливающим чрезвычайно высокую вычислительную сложность задачи восстановления линейной регрессионной модели.

В данной работе для беспереборной минимизации числа регрессоров предлагается использовать основную идею метода RVM (Relevance Vector Machines) [1], название которого можно перевести как «метод уместных (надежных) векторов», заключающуюся в погружении дискретной задачи

выбора подмножества в непрерывную задачу поиска оптимальной совокупности неотрицательных весов, приписываемых элементам исходного множества. Как и получивший чрезвычайно широкую популярность метод опорных векторов SVM (Support Vector Machines) [1], этот метод предназначен для беспризнакового восстановления зависимостей в множествах объектов $\omega \in \Omega$, в которых измеряется лишь их попарное сходство, выражаемое так называемой kernel function $K(\omega', \omega'')$ (потенциальной функцией [1] в исходной русскоязычной терминологии), обладающей свойствами скалярного произведения в некотором непосредственно не наблюдаемом линейном пространстве. В методах SVM и RVM искомая зависимость ищется в виде $y \cong \psi(\omega) = \sum_{i \in \hat{A}} x_i K(\omega, \omega_i)$, где $\hat{A} \subset A = \{\omega_i, i = 1, \dots, n\}$ – некоторое подмножество объектов в обучающей совокупности, называемых, соответственно, «опорными» либо «уместными», но принцип отбора в этих методах совершенно различен.

Потенциальная функция понимается как скалярное произведение некоторых, вообще говоря, лишь воображаемых признаков объектов $K(\omega', \omega'') = \sum_{i=1}^n x_i(\omega') x_i(\omega'')$. Несмотря на всю привлекательность беспризнакового подхода, существует множество прикладных задач, в которых признаки объектов могут быть вычислены непосредственно, и важно отобрать наиболее значимые из них, не прибегая к обременительному перебору.

Вероятностная модель наблюдений

Пусть наблюдаемая величина y понимается как сумма искомой линейной комбинации известных регрессоров $\mathbf{z}^T \mathbf{x} = \sum_{i=1}^n x_i z_i$ и нормальной случайной величины $\sigma \eta$ с нулевым математическим ожиданием и неизвестной дисперсией σ^2 :

$$y = \mathbf{z}^T \mathbf{x} + \sigma \eta, \quad M(\eta) = 0, \quad M(\eta^2) = 1. \quad (1)$$

Неизвестный вектор коэффициентов регрессии $\mathbf{x} = (x_1, \dots, x_n)^T \in R^n$ будем рассматривать, в свою очередь, как случайный, характеризующийся априорным нормальным распределением с независимыми компонентами, имеющими нулевые математические ожидания и неизвестные дисперсии r_i , $i = 1, \dots, n$, образующие вектор $\mathbf{r} = (r_1, \dots, r_n)$.

Тогда условное распределение вектора наблюдений \mathbf{y} относительно неизвестного вектора коэффициентов регрессии есть нормальное распределение с плотностью $\varphi(\mathbf{y} | \mathbf{x}, \sigma; \mathbf{Z}) = N(\mathbf{y} | \mathbf{Z}^T \mathbf{x}, \sigma^2 \mathbf{I})$, определяемой математическим ожиданием $\mathbf{z}^T \mathbf{x}$ и диагональной ковариационной матрицей

$\sigma^2 \mathbf{I}$. Априорное распределение вектора коэффициентов регрессии также является нормальным $p_0(\mathbf{x} | \mathbf{r}) = \mathbf{N}(\mathbf{x} | \mathbf{0}, \text{Diag}(\mathbf{r}))$ с нулевым математическим ожиданием и диагональной ковариационной матрицей $\text{Diag}(\mathbf{r})$. Очевидно, что и полное распределение вектора наблюдений остается нормальным

$$f(\mathbf{y} | \sigma, \mathbf{r}; \mathbf{Z}) = \mathbf{N}(\mathbf{y} | \mathbf{0}, \mathbf{Z}^T [\text{Diag}(\mathbf{r})] \mathbf{Z} + \sigma^2 \mathbf{I}) \quad (2)$$

с нулевым математическим ожиданием и ковариационной матрицей $\mathbf{Z}^T [\text{Diag}(\mathbf{r})] \mathbf{Z} + \sigma^2 \mathbf{I}$, определяемой параметрами модели σ и \mathbf{r} .

Если априорные дисперсии некоторых компонент вектора коэффициентов регрессии в (1) равны нулю $r_i = 0$ или близки к нулю, то, очевидно, соответствующие регрессоры не участвуют либо почти не участвуют в модели. В качестве оценки вектора коэффициентов регрессии по обучающей выборке естественно принять математическое ожидание $\hat{\mathbf{x}}_N(\sigma, \mathbf{r})$ его нормального апостериорного распределения

$p_N(\mathbf{x} | \sigma, \mathbf{r}; \mathbf{y}, \mathbf{Z}) = \mathbf{N}(\mathbf{x} | \hat{\mathbf{x}}_N(\sigma, \mathbf{r}), \hat{\mathbf{R}}_N(\sigma, \mathbf{r}))$, определяемого параметрами

$$\hat{\mathbf{x}}_N(\sigma, \mathbf{r}) = (1/\sigma^2) \hat{\mathbf{R}}_N(\sigma, \mathbf{r}) \mathbf{Z} \mathbf{y}, \quad \hat{\mathbf{R}}_N^{-1}(\sigma, \mathbf{r}) = \text{Diag}(\mathbf{r}^{-1}) + (1/\sigma^2) \mathbf{Z} \mathbf{Z}^T,$$

где $\mathbf{r}^{-1} = (1/r_1, \dots, 1/r_n)$.

Оценивание априорных дисперсий коэффициентов регрессии и дисперсии шума наблюдения

Свободными параметрами модели являются априорные дисперсии коэффициентов регрессии $\mathbf{r} = (r_1, \dots, r_n)$ и дисперсия шума наблюдения σ^2 в (Ошибка! Источник ссылки не найден.). Полную плотность распределения вектора наблюдений (2) естественно использовать как функцию правдоподобия для оценивания этих параметров

$$(\hat{\sigma}_N, \hat{\mathbf{r}}_N) = \arg \max_{(\sigma, \mathbf{r})} f(\mathbf{y} | \sigma, \mathbf{r}; \mathbf{Z}).$$

Эта вогнутая функция легко поддается максимизации с помощью следующего итерационного алгоритма, являющегося разновидностью известной EM процедуры [1,2]:

$$\begin{aligned} \mathbf{r}^{(k+1)} &= \arg \max_{\mathbf{r}} \int_{R^n} p_N(\mathbf{x} | \sigma^{(k)}, \mathbf{r}^{(k)}; \mathbf{y}, \mathbf{Z}) \log p_0(\mathbf{x} | \mathbf{r}) d\mathbf{x}, \\ \sigma^{(k+1)} &= \arg \max_{\sigma} \int_{R^n} p_N(\mathbf{x} | \sigma^{(k)}, \mathbf{r}^{(k)}; \mathbf{y}, \mathbf{Z}) \log \phi(\mathbf{y} | \mathbf{x}, \sigma; \mathbf{Z}) d\mathbf{x}. \end{aligned} \quad (3)$$

Решение задач оптимизации на каждом шаге итерационного алгоритма выражается простыми формулами, поскольку все фигурирующие в (3) распределения вероятностей являются нормальными. Обычно процесс сходится за 10-15 итераций, проявляя ярко выраженную тенденцию к обнулению дисперсий «лишних» коэффициентов регрессии. После того, как найдены оптимальные значения $\hat{\sigma}_N$ и $\hat{\mathbf{r}}_N = (\hat{r}_{N,1}, \dots, \hat{r}_{N,n})$, активные

регрессоры могут быть выбраны, например, по заданному порогу $\hat{r}_{N,i} \geq h$.

В докладе приводятся результаты экспериментов по оцениванию линейной регрессии в условиях малых обучающих выборок.

Литература

1. Akaike H. A new look at statistical model identification. *IEEE Transactions on Automatic Control*, 1974, 41, 716-723.
2. Miller R.G., Jr. *Beyond ANOVA*. Chapman and Hall, London, 1997.
3. Bishop C.M., Tipping M.E. Variational relevance vector machines. In C. Boutilier and M. Goldszmidt (Eds.), *Proceedings of the 16th Conference on Uncertainty in Artificial Intelligence*. Morgan Kaufmann, 2000, pp. 46–53.
4. Vapnik V. *Statistical Learning Theory*. John-Wiley & Sons, Inc. 1998.
5. Айзерман М.А., Браверман Э.М., Розоноэр Л.И. *Метод потенциальных функций в теории обучения машин*. М.: Наука, 1970, 384 с.
6. Dempster A., Laird N., Rubin D. Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society, Series B*, 1977, 39(1), pp.1–38.
7. McLachlan G., Krishnan T. *The EM Algorithm and Extensions*. Wiley Series in Probability and Statistics. John Wiley & Sons, 1997.

Вероятностный принцип формирования потенциальных функций на множествах объектов произвольной природы для беспризнакового распознавания образов и восстановления зависимостей

В.В. Моттль, О.С. Середин

(Москва, Тула)

Введение

Задачи обнаружения эмпирических закономерностей в том или ином множестве объектов $\omega \in \Omega$, в частности, построения регрессионных моделей и распознавания образов, составляют группу наиболее актуальных задач современной информатики. Требуется, анализируя предъявленный массив данных, представляющий собой совокупность значений некоторой характеристики $f(\omega)$, экспериментально измеренных на доступном подмножестве объектов $\Omega^* \subset \Omega$, продолжить эту функцию на все множество Ω , так чтобы можно было в дальнейшем оценивать значение рассматриваемой характеристики $\hat{f}(\omega)$ для новых объектов $\omega \in \Omega \setminus \Omega^*$, не участвовавших в изначально предъявленном массиве [1]. В частности, если характеристика $f(\omega)$ принимает значения из конечного множества, то такие задачи принято называть задачами обучения распознаванию образов, в

случае же действительностнозначной характеристики говорят о восстановлении регрессионной зависимости.

Как правило, в качестве основы для продолжения функции используется гипотеза компактности, заключающаяся в предположении, что объекты $\omega', \omega'' \in \Omega$, отобразившиеся в близкие точки в конечномерном линейном пространстве их признаков $\mathbf{x}(\omega'), \mathbf{x}(\omega'') \in \mathbb{R}^n$, скорее всего обладают совпадающими или, по крайней мере, близкими значениями целевой характеристики $f(\omega)$, например, принадлежат к одному и тому же классу.

Однако существует широкий класс прикладных задач анализа данных, в которых трудно априори указать набор осмысленных признаков объектов. Вместе с тем, как правило, легко удается непосредственно вычислить степень сходства либо несходства двух объектов, так что единственным способом восприятия объекта оказывается его сравнение с другими объектами в предъявленной выборке. Применительно к задачам обучения распознаванию образов такой подход принято называть беспризнаковым [2], хотя этот термин вполне уместен и для других видов анализа данных.

Вообще говоря, гипотеза компактности дает вполне достаточную основу для создания методов беспризнакового анализа данных, поскольку опирается лишь на понятие метрики в множестве объектов, которая может быть определена любым способом, не обязательно через предварительное вычисление значений их признаков. В то же время представление об исходных объектах как о точках некоторого линейного пространства чрезвычайно удобно при конструировании как семейств решающих правил, так и алгоритмов аппроксимация скрытой зависимости в их пределах.

Блестящий компромисс дает метод потенциальных функций [3], особенно в виде вытекающего из него метода опорных векторов [3], в котором к свойствам двухместной функции $K(\omega', \omega'')$, измеряющей попарное сходство объектов (потенциальной функции или kernel function в англоязычной терминологии), предъявляется специальное требование, суть которого сводится к возможности интерпретации ее значений как скалярного произведения элементов некоторого гипотетического линейного пространства, отображающих исходные объекты реального мира.

В данном докладе рассматривается вероятностный подход к построению потенциальных функций на множестве объектов произвольной природы, суть которого заключается в понимании всякого объекта $\omega \in \Omega$ как результата случайного преобразования другого объекта из того же множества $\mathcal{G} \in \Omega$. Множество объектов Ω рассматривается как вероятностное пространство, позволяющее задавать распределения вероятностей их плотностями по некоторой σ -конечной мере. В частности,

если Ω конечно или счетно, то роль плотности распределения вероятностей по считающей мере играет вероятность каждой отдельной реализации.

Потенциальная функция на основе случайного преобразования множества объектов

Основное предположение заключается в том, что исходное представление о сходстве двух объектов $\vartheta, \omega \in \Omega$ может быть выражено в терминах случайного преобразования $\vartheta \rightarrow \omega$, определяемого некоторым заданным семейством условных плотностей распределения вероятностей $\varphi(\omega | \vartheta)$, так что чем выше значение этой плотности, тем больше объект ω «похож» на объект ϑ . Однако величина $\varphi(\omega | \vartheta)$ плохо подходит на роль количественной меры парного сходства объектов уже хотя бы потому, что не является симметричной.

Будем полагать, далее, что на множестве объектов Ω определена плотность распределения вероятностей $p(\vartheta)$, формально выражающая предполагаемое различие «частоты встречаемости» объектов в природе. Сходство двух объектов $\omega', \omega'' \in \Omega$ естественно оценивать значением правдоподобия гипотезы об их происхождении в результате двух независимых преобразований одного и того же неизвестного случайно выбранного объекта, играющего роль общего прототипа:

$$K(\omega', \omega'') = \int_{\vartheta \in \Omega} p(\vartheta) \varphi(\omega' | \vartheta) \varphi(\omega'' | \vartheta) d\vartheta \quad (1)$$

Распределения вероятностей $\varphi(\omega' | \vartheta)$ и $\varphi(\omega'' | \vartheta)$ образуют пару так называемых условно независимых симметричных распределений (Conditionally Symmetrically Independent Distributions), исследованных в работе [5].

Заметим, что семейство условных плотностей распределения $\varphi(\omega | \vartheta)$ ставит в соответствие каждому объекту ω функцию $x_\omega(\vartheta) = \varphi(\omega | \vartheta)$, определенную на всем множестве Ω , которую естественно рассматривать как «образ» этого объекта в линейном пространстве всех действительных функций на Ω . Тогда двухместная функция правдоподобия (1) есть скалярное произведение двух соответствующих функций с весом $p(\vartheta)$ и, следовательно, является потенциальной функцией на множестве объектов.

Эргодичное обратимое случайное преобразование множества объектов

Естественный способ выбора распределения вероятностей $p(\vartheta)$, играющего роль весовой функции в определении потенциальной функции (1), дает дополнительное предположение о свойствах случайного преобразования $\varphi(\omega | \vartheta)$. Будем называть это преобразование эргодичным,

если на Ω существует плотность распределения $\zeta(\omega)$, являющаяся решением интегрального уравнения

$$\zeta(\omega) = \int_{\mathfrak{G} \in \Omega} \varphi(\omega | \mathfrak{G}) \zeta(\mathfrak{G}) d\mathfrak{G}, \quad (2)$$

и обратимым, если выполняется условие

$$\zeta(\mathfrak{G}) \varphi(\omega | \mathfrak{G}) = \zeta(\omega) \varphi(\mathfrak{G} | \omega) \text{ для всех } \mathfrak{G}, \omega \in \Omega. \quad (3)$$

Такой выбор терминов определяется тем, что если рассматривать марковский случайный процесс $(\omega_s, s = 1, 2, 3, \dots)$, определяемый переходными распределениями $\varphi(\omega_s | \omega_{s-1})$, то условие (3) равносильно требованию его эргодичности, тогда $\zeta(\omega)$ есть финальное распределение на множестве Ω . Условие (3) является условием обратимости марковского процесса, т.е. совпадения его вероятностных свойств в прямом и обратном направлении.

Плотность финального распределения вероятностей (2) естественно принять в качестве $p(\mathfrak{G})$ в (1). Тогда обратимость случайного преобразования $\varphi(\omega | \mathfrak{G})$ позволяет выразить потенциальную функцию через двухшаговое случайное преобразование множества объектов $\varphi^{[2]}(\omega'' | \omega')$

$$K(\omega', \omega'') = \zeta(\omega') \varphi^{[2]}(\omega'' | \omega') = \zeta(\omega'') \varphi^{[2]}(\omega' | \omega''),$$

$$\varphi^{[2]}(\omega'' | \omega') = \varphi^{[2]}(\omega' | \omega'') = \int_{\mathfrak{G} \in \Omega} \varphi(\mathfrak{G} | \omega') \varphi(\omega'' | \mathfrak{G}) d\mathfrak{G} = \int_{\mathfrak{G} \in \Omega} \varphi(\mathfrak{G} | \omega'') \varphi(\omega' | \mathfrak{G}) d\mathfrak{G}.$$

В ряде случаев способ определения потенциальной функции через двухшаговое преобразование $\omega' \rightarrow \mathfrak{G} \rightarrow \omega''$, эквивалентный (1), оказывается предпочтительным.

В докладе приводятся примеры потенциальных функций на множествах сигналов и символьных последовательностей разной длины, построенных по изложенному здесь принципу.

Литература

1. Вапник В.Н. Восстановление зависимостей по эмпирическим данным. М.: Наука, 1979.
2. Duin R.P.W, De Ridder D., Tax D.M.J. Experiments with a featureless approach to pattern recognition. Pattern Recognition Letters, 1997, Vol. 18, No. 11-13, pp. 1159-1166.
3. Айзерман М.А., Браверман Э.М., Розоноэр Л.И. Метод потенциальных функций в теории обучения машин. М.: Наука, 1970, 384 с.
4. Vapnik V. Statistical Learning Theory. John-Wiley & Sons, Inc., 1998.
5. Watkins C. Dynamic alignment kernels. In: A.J. Smola, P.L. Bartlett, B. Scholkopf, and D. Schuurmans, Ed. Advances in Large Margin Classifiers.

MIT Press, 2000, pp. 39-50.

Проблемы использования МГУА при неполных и неточных исходных данных

А.Б. Надирадзе

(Москва)

При использовании МГУА [1] обычно предполагается, что исходная выборка не имеет пропусков, представленные в ней данные содержат только Гауссову компоненту шума, а матрица нормальных уравнений не вырождена. Это соответствует случаю, когда выходная величина имеет однозначную связь с входными величинами и количество элементов выборки достаточно велико. Однако часто в исходных данных имеется много пропусков, они содержат не все значащие величины, а объем выборки недостаточен. Кроме того, при использовании МГУА-моделей параметры на входе также могут содержать некоторую ошибку и быть недоопределены. В связи с этим возникает проблема построения и использования МГУА-моделей при неполных и неточных исходных данных.

Два класса моделей

С утилитарной точки зрения модели могут быть использованы для решения двух классов задач – исследовательских и прогнозных.

При решении исследовательских задач требуется получить информацию о внутреннем строении системы и протекающих в ней процессах. Главное требование к модели – адекватность. Точность вычислений (аппроксимации) в данном случае играет второстепенную роль. Основной вопрос – «почему система ведет себя именно так, а не иначе».

В прогнозных задачах ситуация противоположная. Здесь требуется принять решение на основании данных о дальнейшем поведении системы или ее реакции на возможное воздействие. При этом требования к точности вычислений наивысшие, а информация о внутренней природе системы не имеет принципиального значения. Основной вопрос прогнозных задач – «как поведет себя система в будущем».

Можно сказать, что по отношению к описываемой системе исследовательские и прогнозирующие модели являются, соответственно, внутренними и внешними. Естественно, что структура и принципы построения этих моделей должны сильно отличаться.

Построение исследовательских моделей при недостатке информации в принципе не имеет смысла, поэтому проблема неполноты исходных данных решается единственным способом - поиском и привлечением дополнительной информации.

При построении прогнозирующих моделей приходится оперировать только тем объемом информации, который имеется на данный момент

времени. И на основании только этой информации необходимо принять решение. Причем вероятность принятия ошибочного решения должна быть полностью исключена или сведена к минимуму. В этой ситуации проблема неполноты исходных данных может быть решена только за счет снижения точности прогноза.

Но поскольку формализованные модели не содержат информации о точности, использование их для прогноза, особенно в условиях неполноты исходных данных, неизбежно приводит к неопределенности. Поэтому для решения задач прогнозирования требуется принципиально иной тип моделей, который будет содержать информацию о точности.

Концепция граничного МГУА

Информация о точности может быть представлена различными способами, например, предельным или средним отклонением значений выходной переменной от значений, наблюдаемых в эксперименте. Такое представление предполагает, что ошибка является случайной величиной, имеющей нормальное распределение. Однако если в модели неучтены один или несколько значимых параметров, функция ошибок становится существенно сложнее.

Рассмотрим такой пример. Пусть взаимосвязь параметров системы описывается уравнением вида:

$$y = a_1x_1 + a_2x_2 + a_{12}x_1x_2, \quad (1)$$

и пусть имеется серия наблюдений в виде множества пар $R_1 = \{y, x_1\}^M$, где M – количество элементов выборки (количество строк). Переменная x_2 скрыта от наблюдателя и о ней ничего неизвестно (в общем случае, количество неопределенных параметров также неизвестно и, вообще говоря, может быть очень большим). Тогда, если переменные x_1, x_2 независимы и равномерно распределены на интервале (0,1) получим картину, изображенную на рис. 1. А в качестве примера на рис. 2 представлены реальные данные, описывающие зависимость коэффициента распыления [2]

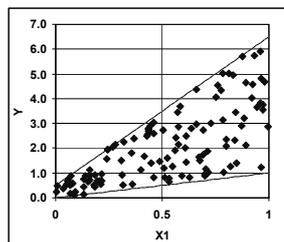


Рис. 1.

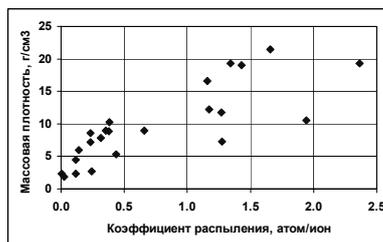


Рис. 2.

от массовой плотности вещества. Здесь ситуация аналогичная рис. 1.

Для описания подобных систем предлагается перейти от поиска одной аппроксимирующей функции к поиску двух граничных функций, между которыми находится выходная величина y . Применительно к рассмотренному примеру это означает, что требуется найти функции (на рис. 1 они показаны пунктиром):

$$\begin{aligned} y_0(x_1) &= a_1 x_1 \\ y_1(x_1) &= a_1 x_1 + a_{12} x_1 + a_2 \end{aligned} \quad (2)$$

такие, что при любых $x_1 \in [0,1]$ $y(x_1) \in [y_0(x_1), y_1(x_1)]$.

Идеи построения МГУА вполне применимы для поиска указанных граничных функций. Критерием отбора моделей кандидатов может являться условие включения всех точек выборки в коридор ошибок, образованный граничными функциями (критерий «полного включения»). Наилучшими аппроксимирующими функциями, прошедшими отбор, будут те, которые образуют коридор ошибок минимального объема (критерий «минимума объема»).

По-видимому, могут быть предложены и другие критерии. Однако, поскольку целью данной работы было формирование концепции метода, вопросы построения критериев и алгоритмов здесь не рассматривались.

Использование граничного МГУА позволяет решить многие проблемы неполноты и неточности исходных данных. Пропуски в данных заменяются интервалами возможных значений параметров, а неточные данные – интервалами неопределенности. При неполноте и неточности вектора исходных данных производятся аналогичные замены. Точность оценки при использовании граничного МГУА зависит от точности и полноты вектора исходных данных, что снимает неопределенность при принятии решений.

Литература

1. Ивахненко А.Г., Юрачковский Ю.П. Моделирование сложных систем по экспериментальным данным. - М.: Радио и связь, 1987.- 120 с.
2. Проблемы прикладной физики. Распыление твердых тел ионной бомбардировкой. Физическое распыление одноэлементных твердых тел / Под ред. Р. Бериша: Пер. с англ./ Под ред. В.А. Молчанова. М.: 1984. - 336 с.
3. Нариньяни А.С. Недоопределенные модели и операции с недоопределенными значениями // Препринт АН СССР. Сиб. Отд.-ие. ВЦ; Т400; Новосибирск, 1982. - 33 с.

Оценка смещения эмпирической оценки риска решающей функции

В. М. Неделько
(Новосибирск)

Введение

При построении решающей функции, в том числе в задачах распознавания образов, возникает необходимость оценивания риска, или вероятности ошибочной классификации новых объектов. Чаще всего такая оценка строится по контрольной выборке или методом скользящего экзамена. Однако оба метода имеют существенные недостатки: первый уменьшает доступный для обучения объем выборки, второй — имеет значительную трудоемкость и, как правило, не позволяет оценить доверительный интервал для риска. Кроме того, эти методы вообще неприменимы, если оценка риска должна использоваться в качестве критерия при выборе решающей функции.

Указанных недостатков лишен подход, основанный на непосредственном оценивании риска по обучающей выборке, или эмпирическому риску [1]. Однако, эмпирический риск (доля ошибочно классифицированных объектов обучающей выборки) является смещенной оценкой для риска, причем смещение зависит от распределения в пространстве характеристик объектов.

В работе [1] предложен универсальный подход, основанный на понятии функции роста или емкости класса решающих функций, и даны оценки риска для задачи классификации. Вместе с тем, предложенные оценки являются существенно завышенными, и стоит задача их уточнения.

Максимальное смещение эмпирического риска в дискретном случае

Смещение эмпирического риска есть разность $E R - E \tilde{R}$, где R – риск, \tilde{R} – эмпирический риск.

Однако данная величина зависит от распределения в пространстве переменных, которое нам неизвестно. Ориентируясь на «худший» случай, введем функцию максимального смещения:

$$S(\tilde{R}_0) = \sup_{E\tilde{R}=\tilde{R}_0} ER - \tilde{R}_0,$$

где супремум берется по всем распределениям, для которых средний эмпирический риск составляет заданную величину.

В общем случае решить приведенную оптимизационную задачу пока не представляется возможным. Для случая дискретного пространства изолированных точек удастся найти точное решение [3,4]. Полученный результат позволяет, в частности, продемонстрировать степень завышенности оценок Вапника–Червоненкиса.

На рис. 1 приведена (сплошная линия) зависимость $S(\tilde{R}_0)$ для случая, когда на точку пространства переменных приходится в среднем 5 объектов выборки.

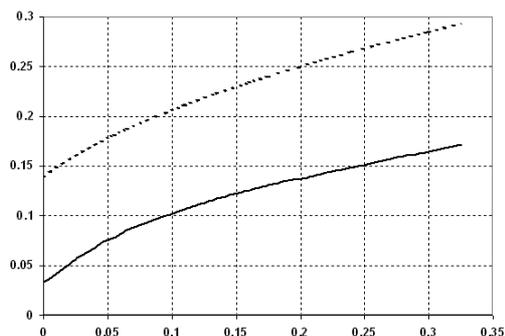


Рис. 1. Точное смещение эмпирического риска и его оценка.

Пример показывает существенную завышенность оценки Вапника–Червоненкиса (отображена пунктиром), которая объясняется, вероятно, используемой в [1] заменой вероятности суммы событий суммой их вероятностей.

Непрерывный случай

На практике рассмотренный дискретный случай малополезен и служит лишь для демонстрации точности оценок. Возникает вопрос, можно ли перенести результат на общий случай.

На рис. 2 для примера приведен результат моделирования смещения

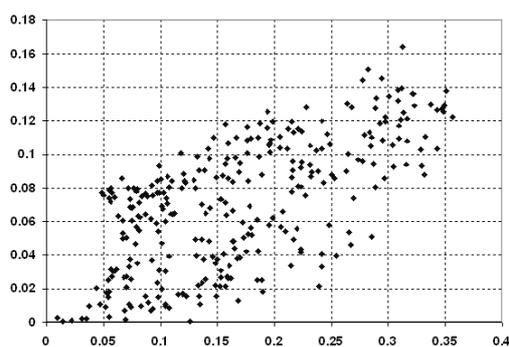


Рис. 2. Моделирование смещения риска для дискриминанта Фишера.

эмпирического риска для дискриминанта Фишера. По горизонтали

откладывается значение $E \tilde{R}$, по вертикали — разность $E R - E \tilde{R}$. Каждая точка соответствует случайно сконструированному распределению в двумерном пространстве переменных.

Результаты предварительных исследований позволяют выдвинуть гипотезу, что зависимость $S(\tilde{R}_0)$ имеет универсальную форму, и полученный для дискретного пространства ее вид сохраняется и в более сложных примерах.

Литература

1. Вапник В. Н., Червоненкис А. Я. Теория распознавания образов. // М.: Наука, 1974. 415 с.
2. Неделько В. М. Оценивание доверительного интервала для вероятности ошибки решающей функции распознавания по эмпирическому риску. // Доклады Всероссийской конференции "Математические методы распознавания образов", Изд-во ВЦ РАН, Москва, 1999.
3. Nedelko V. M. An Asymptotic Estimate of the Quality of a Decision Function Based on Empirical Risk for the Case of a Discrete Variable. // Pattern Recognition and Image Analysis, Vol. 11, No. 1, 2001, pp. 69-72.
4. Nedelko V. M. Estimating a Quality of Decision Function by Empirical Risk // LNAI 2734. Machine Learning and Data Mining in Pattern Recognition. Third International Conference, MLDM 2003, Leipzig. Proceedings. Springer-Verlag. pp. 182–187.

Адаптивная управляемая динамическая система расознавания на основе метода наименьших квадратов

Ю.И. Неймарк, Л.Г. Теклина

(Нижний Новгород)

Введение

Метод наименьших квадратов (МНК) – один из наиболее широко используемых математических методов обработки и анализа больших массивов данных. Для преодоления трудностей, возникающих при использовании МНК, и придания методу адаптивных свойств авторами предложена универсальная рекуррентная формы МНК и ее реализация в виде адаптивной управляемой динамической системы [1]. Универсальная рекуррентная форма МНК основана на решении системы нормальных уравнений и включает в себя шесть наборов рекуррентных процедур: по числу данных в выборке, по определяемым параметрам, по количеству ограничений на параметры, причем возможные изменения включают в себя как увеличение, так и сокращение и выборки, и описания, и ограничений. Универсальность введенных рекуррентных процедур заключается также в общности формул как для случая наличия линейных ограничений на

оцениваемые параметры, так и при отсутствии таких ограничений. Полнота введенных операций открывает новые более широкие возможности приложений и использования МНК. Процесс обработки данных с использованием рекуррентного МНК – управляемый динамический процесс. Управление системой состоит в выборе на каждом шаге необходимой рекуррентной процедуры и текущего входного воздействия для перехода системы в новое состояние. Выбор управления определяется результатами анализа информации с помощью МНК, числовыми показателями качества решения (значения функционала) и данными, поступающими на вход системы. В качестве одного из приложений этой системы предлагается ее использование при решении задач распознавания.

Постановка задачи распознавания с учителем как проблемы МНК

Рассматривается задача распознавания с учителем на основе обучающей последовательности \mathbf{X} , представленной в виде совокупности выборок для каждого из распознаваемых образов (классов). Элемент обучающей

последовательности $\mathbf{x}^j \in \mathbf{X}$ ($j=1, \dots, M$) - это описание объекта распознавания с помощью набора признаков, используемых для характеристики объектов. В общем случае каждый из признаков может изменяться с течением времени, а время наблюдения может быть своим для каждого из изучаемых объектов, т.е. $\mathbf{x}^j = (\mathbf{x}^j(t_{j_1}), \dots, \mathbf{x}^j(t_{j_{k_j}}))$ и

$\mathbf{x}^j(t_{j_v}) = (x_1^j(t_{j_v}), \dots, x_n^j(t_{j_v}))$. Классическая задача распознавания, когда каждый объект – это одна точка в n -мерном пространстве признаков, соответствует $k_j = 1 \quad \forall j = 1, \dots, N$. При $n=1$ и $k_j > 1$ имеет место задача распознавания сигналов. В случае $k_j > 1$ и $n > 1$ решается задача распознавания многомерных динамически изменяющихся объектов.

Решение задачи распознавания с помощью МНК складывается из 3 основных этапов:

- сокращение размерности описания;
- моделирование динамики изменения объектов во времени;
- построение решающего правила распознавания.

Дадим краткую характеристику каждому из этапов, начиная с последнего.

Построение решающего правила распознавания с помощью МНК трактуется как задача аппроксимации функции учителя и решается путем минимизации функционала

$$J(\mathbf{a}, \mathbf{b}, \mathbf{C}) = \sum_{j=1}^N \left(\sum_{i=1}^m a_i \varphi_i(\mathbf{z}^j, \mathbf{C}, \xi_{\mu\nu}) - b_j \right)^2$$

по параметрам \mathbf{a} , \mathbf{b} , \mathbf{C} , где функция $\sum_{i=1}^m a_i \varphi_i(\mathbf{z})$ задает вид решающего правила и определяется выбором системы базисных функций $\{\varphi_i(\mathbf{z})\}$ и оцениваемыми с помощью МНК параметрами \mathbf{a} , b_j - код образа,

к которому принадлежит объект \mathbf{x}^j [2], а параметры \mathbf{C} и системы базисных функций $\{\xi_{\mu\nu}(\mathbf{z})\}$ определяют адаптивную нелинейную метрику [3] в пространстве новых признаков \mathbf{z} . Новое описание для объектов из обучающей выборки формируется на этапах 1-2 решения задачи распознавания.

Необходимость сокращения описания определяется постановкой задачи, типом задания данных и объемом обучающей выборки, а возможности и пути для такого сокращения выясняются в ходе анализа представленных данных [4]. С использованием только МНК предлагаются два пути сокращения описания: построение приспособленного адаптивного базиса и построение дискриминантных признаков [5]. Обе задачи решаются на основе минимизации квадратичного функционала с линейными ограничениями на параметры

$$\begin{cases} J_1(\alpha_1, \beta_1) = \sum_{j=1}^{N_1} \left(\sum_{i=1}^{m_1} \alpha_{1i} \theta_{1i}(\mathbf{x}^j) - \beta_{1j} \right)^2, \\ \mathbf{G}\alpha_1 = \mathbf{d}_1 \end{cases}$$

где $\{\theta_{1i}(\mathbf{x})\}$ - система функций, задающая тип искомого нелинейного многообразия, β_1 - коды распознаваемых множеств, α_1 - параметры, определяющие либо базисные орты, либо направление максимальной различимости образов. Новое описание \mathbf{x}_1 формируется в виде проекций объектов на выбранные направления.

При распознавании временных рядов возникает необходимость в построении параметрических математических моделей, описывающих динамику изменения объектов во времени. Параметры модели, определяемые из условия минимизации функционала вида

$$J_2(\alpha_2) = \sum_{j=1}^{N_2} \left(\sum_{i=1}^{m_2} \alpha_{2i} \theta_{2i}(\mathbf{x}_1^j) - \beta_{2j} \right)^2$$

($\{\theta_{2i}(\mathbf{x}_1)\}$ - система функций для описания модели) служат новым описанием для динамически изменяющихся объектов.

Работа выполнена при поддержке РФФИ (проект 02-01-00274).

Литература

1. Ю.И. Неймарк., Л.Г. Теклина Метод наименьших квадратов как

- управляемая динамическая система. // Электронный журнал "Исследовано в России", 59, 641-650, 2002. <http://zhurnal.ape.relarn.ru/articles/2002/059.pdf>.
2. Неймарк Ю.И., Теклина Л.Г. Роль кодирования образов при распознавании // Докл. РАН. 1998. Т.363. №6. С.751-752.
 3. Неймарк Ю.И. Обучаемая метрика как интеллект распознавания. // Докл. РАН, т.349, №6, 1996. С. 749-751.
 4. Ю.И. Неймарк, Л.Г. Теклина Решение задачи распознавания многомерных временных рядов на основе редукции размерности. // Сб. Математические методы распознавания образов. Доклады X Всероссийской конференции. М., 2001. С.96-99.
 5. Неймарк Ю.И., Теклина Л.Г. Построение дискриминантных признаков на основе кодирования распознаваемых образов. // Сб. Тезисы докладов международной научной конференции ИОИ-2002. Симферополь: КНЦ НАН Украины, 2002. С.72-73.

Сжатие описания для изменяющихся массивов данных

Ю.И. Неймарк, Л.Г. Теклина

(Нижний Новгород)

Введение

Самый известный способ уменьшения размерности описания для многомерных данных состоит в обнаружении зависимостей между признаками и сокращении их числа за счет удаления зависимых. Геометрически эта задача интерпретируется как нахождение в исходном пространстве признаков подпространства меньшей размерности, в котором располагаются все точки рассматриваемого множества. Простейший случай такого подпространства – линейное многообразие. Построение нелинейного многообразия осуществляется путем перехода к спрямляющему пространству нелинейных базисных функций.

Существуют два наиболее используемых метода решения этой задачи: метод ортогональных компонент, осуществляющий среднеквадратичную аппроксимацию заданного множества [1] и хорошо приспособленный базис с равномерным, чебышевским, приближением данных [2]. Проблемы возникают при обработке изменяющихся массивов данных, когда первоначально найденные закономерности должны быть откорректированы в соответствии с поступлением новой информации. В связи с этим возникла мысль об использовании для решения этой задачи универсальной рекуррентной формы метода наименьших квадратов (МНК) [3], обладающей большими адаптивными возможностями. В работе [4] предложен алгоритм построения адаптивного базиса, основанного на рекуррентном МНК, в виде последовательности ортогональных гиперплоскостей, осуществляющих

среднеквадратичную аппроксимацию анализируемого массива данных. Однако, предложенный базис не обладает оптимальными свойствами. Оказалось, что путем добавления к предложенному алгоритму итеративной процедуры можно получить сколь угодно точное оптимальное решение поставленной задачи.

Постановка задачи

Строится аппроксимирующее, в общем случае нелинейное, многообразие, определяемое базисными функциями $\varphi_1(\mathbf{x}), \varphi_2(\mathbf{x}), \dots, \varphi_m(\mathbf{x})$, для массива данных $\mathbf{X} = \{\mathbf{x}^1, \mathbf{x}^2, \dots, \mathbf{x}^N\}$, $\mathbf{x}^j \in \mathbf{R}^n$. Последовательность вложенных друг в друга подпространств находится путем последовательного решения для $k=1, 2, \dots, m$ следующих задач условной оптимизации

$$J_{sk}(\mathbf{a}_{sk}, b_{sk}) = \min_{\mathbf{a}} \sum_{j=1}^N \left(\sum_{i=1}^n a_i \varphi_i(\mathbf{x}^j) - b \right)^2, \quad (1)$$

$$\alpha_1 a_1 + \dots + \alpha_m a_m = 1$$

$$(\mathbf{a}, \mathbf{a}_{s1}^*) = \dots = (\mathbf{a}, \mathbf{a}_{s,k-1}^*) = 0$$

где с целью использования универсальной рекуррентной формы МНК условие $|\mathbf{a}| = 1$ для оптимальной задачи заменено некоторым линейным ограничением вида $\alpha_1 a_1 + \dots + \alpha_m a_m = 1$.

Описание итеративного процесса

1. В качестве начального приближения на k -ом шаге может быть взято решение задачи (1) в условиях отсутствия ограничения $\alpha_1 a_1 + \dots + \alpha_m a_m = 1$ (задача 1').

2. Присваиваем $p=1$ и вводим первое дополнительное линейное ограничение $a_s = 1$. Путем использования операции увеличения числа ограничений находим решение задачи (1): $(\mathbf{a}_{sk}^1, b_{sk}^1)$ и соответствующее значение функционала J_{sk}^1 .

3. Увеличиваем p на 1. Исключив введенное на предыдущем шаге ограничение, вводим другое ограничение $\left(\mathbf{a}_{sk}^{p-1} \left| \mathbf{a}_{sk}^{p-1} \right|^{-1}, \mathbf{a} \right) = 1$ и с помощью рекуррентных процедур находим $\mathbf{a}_{sk}^p, b_{sk}^p, J_{sk}^p$. Если

выполняется неравенство $\left| \mathbf{a}_{sk}^p \left| \mathbf{a}_{sk}^p \right|^{-1} - \mathbf{a}_{sk}^{p-1} \left| \mathbf{a}_{sk}^{p-1} \right|^{-1} \right| < \varepsilon$, то

итеративный процесс поиска $\mathbf{a}_{sk}^* = \mathbf{a}_{sk}^p \left| \mathbf{a}_{sk}^p \right|^{-1}$ завершен. В противном случае итеративный поиск продолжается путем повторения этого этапа.

Утверждение 1. \mathbf{a}_{sk}^* является k -ым собственным вектором информационной матрицы, соответствующим k -ому минимальному собственному значению $J_{sk}^* = J(\mathbf{a}_{sk}^*, b_{sk}^*)$.

Итак, введение описанной выше итеративной процедуры, привело к построению оптимального подпространства, осуществляющего среднеквадратичную аппроксимацию заданного множества (независимо от выбора s -ой компоненты, за исключением некоторых особых случаев). Однако, наличие итеративной процедуры удлиняет процесс адаптации решения к изменениям в массиве данных в сравнении с простым адаптивным МНК – базисом (этапы 1 и 2 приведенного алгоритма).

Оптимизационные характеристики адаптивного МНК - базиса

Пусть J_k^* - оптимальное значение функционала, отвечающее k -ому минимальному собственному вектору \mathbf{a}_k^* , а J_{sk}^1 - значение, отвечающее решению задачи (1) при ограничении $a_s = 1$.

Утверждение 2. $J_{sk}^1 \left| \mathbf{a}_{sk}^1 \right|^{-2} - J_k^* \leq (\cos^{-2} \beta_{sk}^* - 1) J_k^*$, где β_{sk}^* - угол между направлением оси Oa_s и вектором \mathbf{a}_k^* .

Это означает, что чем меньше значение функционала J_k^* и чем ближе направление Oa_s к направлению собственного вектора, тем меньше различаются по направлению вектора \mathbf{a}_k^* и \mathbf{a}_{sk}^1 . Поэтому при необходимости обработки потоковых данных и достаточности для решения задачи квазиоптимального приближения можно ограничиться адаптивным МНК – базисом относительно некоторой s -ой компоненты.

Работа выполнена при поддержке РФФИ (проект 02-01-00274).

Литература

1. Рао С.Р. Линейные статистические методы и их применения.

- М.: Наука, 1968.
2. Ю.Г. Васин. «Хорошо приспособленные» базисы и задачи обработки экспериментальной информации. Горький, изд. ГГУ, 1979.
 3. Ю.И. Неймарк., Л.Г. Теклина Метод наименьших квадратов как управляемая динамическая система. // Электронный журнал “Исследовано в России”, 59, 641-650, 2002. <http://zhurnal.ape.relarn.ru/articles/2002/059.pdf>.
 4. Neimark Yu.I., Teklina L.G. Recurrent procedures of the least-squares method under restrictions on parameters in coding and recognition problems.//Pattern recognition and image analysis, v.11, no.1, 2001. Pp.228-230.

**О метрических методах интеллектуальной обработки
данных**
Г.В. Никитов
(Москва)

Технология интеллектуальной обработки данных – Data mining – возникла как средство для выявления структур и закономерностей в больших объемах данных. Эта область информатики сегодня широко развивается вместе с ростом количества в том или ином виде накапливаемых, необработанных данных. Алгоритмы Data mining включают в себя такие методы обработки данных, как кластеризация, классификация, извлечение ассоциативных правил и обнаружение зависимостей. Существует подход, который основывается на использовании метрик, то есть пространство, в котором происходит обработка, метризуется [1].

Метрики в рамках технологии Data mining – это инструмент для изучения данных. Метрические методы сводятся к методам построения метрик и их последующего использования. Построение метрик включает в себя оптимизацию и организацию взаимодействия с экспертом. При этом возникает феномен, характерный и общий для задач Data mining, заключающийся в том, что исследователю интересны закономерности, которые проявлены достаточно надежно, но и не сверх явно выражены, так как в этом случае они наверняка и так уже известны экспертам.

В соответствии с этим, в докладе обсуждается проблема введения соответствующего формализма и использования указанных идей в рамках схемы, в которой рассматриваются хранилища данных (по сути – хранилища описаний объектов) и механизм генерации метрик (в широком смысле, включая их обработку и представление в виде, удобном для экспертного анализа).

Параллельно рассматривается механизм оценивания качества метрик, который позволяет установить обратную связь, а механизм генерации

дополнить механизмом оптимизации. Соответственно, возникает класс функционалов для оценки качества метрических конфигураций. При этом важной проблемой оказывается обучение в том смысле, что необходимо организовать взаимодействие с экспертом, результаты оценки которого учитываются в виде функционалов оценки качества.

По своей природе функционалы оценки качества, естественно, дают максимальную оценку для наиболее тривиальных ситуаций, поэтому, имея в виду соображение профессора А. Тужилина, предлагается в механизм настройки включать вместе с монотонными корректорами, действующий над функционалами качества, механизм немонотонной унимодальной коррекции.

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (проект № 02-01-00326).

Литература

1. Никитов Г.В., Рудаков К.В. О структуре метрических технологий Data Mining // Искусственный интеллект. Донецк, 2002 г. №2, с. 218-220.

Задачи классификации со связанными объектами

М.А. Никифоров

(Москва)

Пусть в задаче классификации объекты характеризуются векторами значений признаков (p_1, p_2, \dots, p_n) и дополнительно известно о связях между ними. Формально, мы должны учесть возникающие отношения эквивалентности ρ_k на объектах. Эти связи можно также выразить через использование при индексации векторов не одного, а нескольких индексов, но проще интерпретировать ρ_k как дополнительный признак. Тогда можно называть те объекты, на которых $\rho_k(p) = i$, «объектами типа i » в смысле ρ_k .

Алгоритм распознавания должен коммутировать с перестановками строк матрицы информации U двух типов.

Допустимы перестановки σ_s строк матрицы U в блоке, отвечающем одному и тому же значению признака, и, кроме того, перестановки блоков целиком σ_r , означающие однородность объектов одного типа. Тогда $\sigma_s \times \sigma_r \subset \sigma$ и отображения образуют допустимую подкатегорию симметрической категории в рамках теории универсальных и локальных ограничений.

Следующее требование – чтобы все элементы финальной матрицы,

выражающие соотношение принадлежности объектов типа i классу j , зависели бы от всего набора векторов такого типа по одному и тому же правилу. Категория Φ таких отображений является подкатегорией функциональной категории с функциональной сигнатурой $\varphi = (S_{(1,1)}, \dots, S_{(q,l)}, \lambda)$, задающей порядок подстановки элементов матрицы информации U на места переменных в функции $f_{\lambda(i,j)}$, осуществляющих отображение. Наборы $S_{(i,j)}$ содержат "места" элементов U для каждого элемента информационной (финальной) матрицы. В частности, если каждому типу объектов соответствует блок из m строк матрицы информации, то $S_{(i,j)}$ - это $(m \times m)$ матрица перестановок номеров этих строк, так как "области зависимости" элементов информационной матрицы объектов типа i совпадают по составу, но имеют различный внутренний порядок с точки зрения соответствия аргументам функции f_{λ} . У допустимой сигнатуры перестановки в $S_{(i,j)}$ таковы, что каждая строка и каждый столбец не содержат повторяющихся чисел. Тогда перестановки строк и столбцов в этой матрице сохраняют свойство допустимости.

По доказанной в [1] лемме из допустимости функциональной сигнатуры следует допустимость и полнота категории.

Базой категории Φ будет матрица информации U , не имеющая совпадающих блоков, если функция одна для всех объектов. А, в общем случае, для двух разных типов объектов, распознаваемых одной и той же функцией, наборы величин из матрицы U должны различаться.

Отношения эквивалентности над объектами могут изначально присутствовать в предметной области. Например, при исследовании структуры клиентской среды биржевого рынка потребуется определить принадлежность участника к заданному классу. Каждый из участников обычно торгует по нескольким акциям. Тогда ему можно поставить в соответствие некий набор векторов признаков. В биржевой задаче объектами оказываются пары «участник - ценная бумага».

Литература

1. Рудаков К.В. Об алгебраической теории универсальных и локальных ограничений для задач классификации // Распознавание, классификация, прогноз. М.:Наука, 1989. с. 176-201.

Исследование и классификация функций посредством глубокого разложения в ортогональные ряды

А.Н. Панкратов

(Пушино)

При решении некоторых информационных задач встает необходимость работы с достаточно длинными ортогональными рядами. Например, спад свободной индукции в современном импульсном методе ядерного магнитного резонанса является довольно сложной функцией. При разложении такого сигнала по базису Лагерра требуются тысячи коэффициентов разложения. Комбинирование символьных и численных методов [1] для таких разложений содержит в себе определенные трудности, которые целесообразно рассматривать на простых моделях.

С точки зрения функционального анализа ортогональные разложения охватывают достаточно широкий класс функций интегрируемых с квадратом и предоставляют возможность классификации функций на основе коэффициентов разложения, являющихся интегральными характеристиками сигнала. Одним из признаков классификации функций по их ортогональному разложению может служить степень гладкости функции (дифференцируемость и не дифференцируемость в той или иной степени, фрактальная размерность), которая находит отражение в асимптотическом порядке убывания коэффициентов разложения.

Получение и обработка длинных ортогональных рядов предъявляет высокие требования к устойчивости соответствующих алгоритмов. Поэтому в докладе уделено особое внимание оригинальному программному обеспечению. Программа Адап [2] построена на основе библиотеки процедур `approximation library`, написанной на языке низкого уровня (C++), и представляет собой интерактивное приложение для операционной системы Windows. Она позволяет визуализировать и аппроксимировать произвольные табличные данные. Программа предназначена как для первоначального ознакомления с обобщенным спектрально-аналитическим методом [1], так и для профессионального использования, например, для вычисления узлов и весов квадратурных формул Гаусса высокого порядка, коэффициентов разложения, удаления трендов, определения частотной характеристики различных сигналов. Возможность импортирования и экспортирования данных из программы позволяет комбинировать различные программные средства для решения поставленных задач. Проводимые исследования выполняются при финансовой поддержке РФФИ (проекты 01-07-97060, 01-07-90317, 01-01-00894)

Литература

1. Ф.Ф.Дедус, С.А.Махортых, М.Н.Устинин, А.Ф.Дедус. Обобщенный спектрально-аналитический метод обработки информационных массивов.// М. Машиностроение. 1999. с.356.

2. <http://mail.impb.psn.ru/~pan/>

Об одном подходе к понижению значности исходной информации в задачах распознавания

Н.В. Песков, А.А. Сахаров

(Москва)

В прикладных задачах распознавания признаки обычно являются либо вещественнозначными, либо дискретными высокой значности, что существенно затрудняет использование логических процедур распознавания. Вещественнозначная информация может трактоваться как частный случай дискретной информации высокой значности. Логические процедуры распознавания основаны на сравнении фрагментов описаний классифицируемых объектов с соответствующими фрагментами описаний объектов обучающей выборки. При высокой значности исходной (обучающей) информации каждый из обучающих объектов порождает много уникальных информативных фрагментов (такие фрагменты встречаются только в подписании этого объекта). При этом не только объекты разных классов, но и объекты одного класса могут сильно отличаться друг от друга, и в результате логические процедуры распознавания оказываются не эффективными. Попытки понизить значность с помощью увеличения порогов функции близости между значениями признаков могут привести к тому, что описания объектов из разных классов будут совпадать. Один из способов решения этой проблемы – корректное перекодирование исходной информации. Под корректным перекодированием понимается такое преобразование указанной информации, при котором описания объектов из разных классов остаются различимыми. Идея построения корректных перекодировок принадлежит Ю.И. Журавлеву. Задача сводится к построению покрытий булевой матрицы, которая специальным образом строится по исходной информации. Каждому покрытию этой матрицы соответствует некоторая корректная перекодировка. Число покрытий, а следовательно, и число корректных перекодировок растет экспоненциально с ростом размеров задачи. С таким большим числом перекодировок трудно оперировать, поэтому актуальным и сложным является вопрос выбора «наилучших» (в смысле качества распознавания) перекодировок.

В докладе предложен подход к оценке качества перекодировки T , основанный на анализе информативности (типичности) значений признаков в перекодированной таблице обучения. Данный подход позволяет строить хорошие в смысле качества распознавания перекодировки.

Из двух перекодировок лучшей считается та, при которой число типичных значений в перекодированной таблице обучения больше. При этом оценка типичности значения признака для класса вычисляется на

основе анализа его встречаемости в данном классе и в остальных классах [1, 2]. Значение признака типично для класса K , $K \in \{K_1, \dots, K_l\}$, если

$$\frac{v_1}{|K|} - \frac{v_2}{|\bar{K}|} > \varepsilon_j,$$

где v_1 , v_2 показывают сколько раз признак x_j принимает данное значение соответственно в K и \bar{K} , ε_j – заранее зафиксированный порог типичности ($-1 \leq \varepsilon_j \leq 1$).

Введем величину

$$I_{ij} = \begin{cases} 1, & \text{если } a_{ij} \text{ типично для своего класса} \\ 0, & \text{в противном случае.} \end{cases}$$

Обозначим

$$I_j = \sum_{t=1}^l \frac{1}{m_t n} \sum_{i=1}^{m_t} I_{ij}$$

$$I = \sum_{j=1}^n I_j,$$

где m_t – число объектов в классе K_t . Величину I назовем информативностью перекодировки T , а величину I_j – информативностью признака x_j . На основе сравнения информативностей всех возможных перекодировок мы можем выбрать одну или несколько таких перекодировок, для которых величина I будет максимальна.

Согласно определению информативность признака не зависит от значений остальных признаков. Поэтому можно существенно сократить перебор при поиске перекодировки, обладающей максимальной информативностью. С этой целью каждый столбец исходной таблицы перекодируется независимо от остальных. Получается, вообще говоря, не корректная перекодировка. Множество перекодировок для каждого столбца, а следовательно и множество всех перекодировок таблицы обучения упорядочивается в сторону уменьшения информативности. В указанном порядке осуществляется перебор перекодировок и проверка на корректность. Первая найденная корректная перекодировка является искомой.

Предложенная методика была апробирована на реальных задачах из области медицинского прогнозирования. На полученных перекодировках, алгоритм голосования по представительным наборам показывал большую эффективность, чем на перекодировках, используемых ранее. Эффективность алгоритма оценивалось точностью распознавания при проведении скользящего контроля.

Работа выполнена при финансовой поддержке РФФИ (код проекта 01-01-00575).

Литература

1. Дюкова Е.В., Песков Н.В., Поиск информативных фрагментов описаний объектов в дискретных процедурах распознавания // Ж. вычисл. матем. и матем. физ. 2002. №6, Том 42.
2. Djukova E.V., Peskov N.V., Selection of Typical Objects in Classes for Recognition Problems // Pattern Recognition and Image Analysis. Vol. 12, No. 3, 2002, pp. 243-249.

Алгоритм спектрального расщепления проверки изоморфизма графов и его приложения

А.В. Пролубников, Р.Т. Файзуллин

(Омск)

Задача проверки изоморфизма графов

Задача проверки изоморфизма графов принадлежит к задачам, относительно которых нет ясности: являются ли они полиномиально разрешимыми или нет [1]. Известно, что задача полиномиально разрешима для некоторых классов графов. В частности, для планарных графов, графов с ограниченной степенью вершин, графов с ограниченной кратностью собственных значений их матриц смежности и некоторых других построены эффективные алгоритмы решения задачи проверки изоморфизма графов [2],[3],[4]. Задача проверки изоморфизма невзвешенных неориентированных графов формулируется следующим образом. Даны два невзвешенных неориентированных графа G_A и G_B с множествами вершин V_A, V_B и множествами ребер E_A, E_B . $|V_A| = |V_B|, |E_A| = |E_B|$. Графы изоморфны тогда и только тогда, когда существует биективное отображение $\varphi: V_A \rightarrow V_B$ такое, что $(i, j) \in E_A \Leftrightarrow (\varphi(i), \varphi(j)) \in E_B$.

Алгоритм спектрального расщепления проверки изоморфизма графов

Изоморфность графов равносильна возможности получения матрицы смежности одного графа некоторой перестановкой строк с такой же перестановкой столбцов (перестановкой рядов) матрицы смежности второго

графа. То есть допустима следующая постановка задачи проверки изоморфизма графов эквивалентная приведенной выше. Даны матрицы смежности графов – A_0 и B_0 . Требуется найти матрицу перестановки P такую, что $A_0 = PB_0P^{-1}$, или показать, что такой не существует.

Если спектры матриц смежности $Sp(A_0)$ и $Sp(B_0)$ просты, то есть не содержат кратных собственных значений, имеет место критерий:

$$G_A \cong G_B \Leftrightarrow Sp(A_0) = Sp(B_0) \text{ и } \exists! P : \forall j v_A^j = P v_B^{\varphi(j)},$$

где P – некоторая матрица перестановки, φ – изоморфизм, реализуемый перестановкой вершин, соответствующей перестановке рядов матрицы, реализуемой P , $v_A^j, v_B^{\varphi(j)}$ – собственные векторы A_0 и B_0 . Группа автоморфизмов графа (изоморфных отображение множества вершин графа на себя) реализуется множеством всех матриц перестановок, которые коммутируют с матрицей смежности графа. Если группа автоморфизмов $\Gamma(G_A)$ графа не тривиальна, что соответствует наличию симметрий в графе относительно перестановок его вершин, то $Sp(A_0)$ содержит кратные собственные значения [5], и приведенный выше критерий места не имеет: матрица P – не единственна, и установление изоморфизма покомпонентным сравнением собственных векторов невозможно. Возможно возмущение матриц смежности обоих графов до некоторых матриц A и B таких, что $A_0 = PB_0P^{-1} \Leftrightarrow A = PBP^{-1}$, и $Sp(A)$ – простой. Однако, вычисление спектра и всех собственных векторов матрицы, а главное, вычисление матрицы, при помощи которой должно быть произведено возмущение, – задача вычислительно значительно более тяжелая, чем решение систем линейных алгебраических уравнений, с которыми работает рассматриваемый ниже алгоритм спектрального расщепления проверки изоморфизма графов. Предлагаемый нами алгоритм работает с модифицированными матрицами смежности графов и основан на решении связанных с ними систем линейных алгебраических уравнений. Построение изоморфизма, если графы изоморфны, происходит на итерациях алгоритма без осуществления ветвления в соответствии с некоторым деревом поиска. Изоморфны графы или нет устанавливается не более чем за n итераций алгоритма, где n – число вершин в графах. Графам G_A и G_B ставятся в соответствие положительно определенные матрицы с диагональным преобладанием. На итерациях алгоритма решаются системы линейных уравнений, дающие матрицы A^{-1} и B^{-1} . Поскольку

$A = PBP^{-1} \Leftrightarrow A^{-1} = PB^{-1}P^{-1}$, то проверяются на равенство с точностью до перестановки компонент полученные векторы-решения систем линейных уравнений. Последовательно возмущая матрицы A и B в ходе работы алгоритма, мы разрушаем симметрии в графе и не более чем за n итераций приходим к ситуации, когда возможно установление изоморфизма графов. На итерациях алгоритма происходит последовательное возмущение рабочих матриц алгоритма, такое, что сохраняется возможность получения матриц, поставленных в соответствие графам, некоторой перестановкой их рядов. То есть на любой j -ой итерации для рабочих матриц алгоритма выполняется: $A^j = PB^jP^{-1} \Leftrightarrow A^{j-1} = PB^{j-1}P^{-1}$.

Возмущая матрицы, удается достичь численно эффективного расщепления как спектров матриц, так и норм решений систем линейных уравнений, что позволяет в случае изоморфизма графов установить взаимно однозначное соответствие. Расщепление достигается при заданной на старте алгоритма длине мантиссы машинных чисел и заданном числе итераций решения систем линейных уравнений. Доказана оценка границ интервала, в котором происходит расщепление норм решений систем линейных уравнений, относительно возмущений матриц, позволяющая определить трудоемкость алгоритма как полиномиальную для широкого класса графов, включая указанные в [2], [3], [4], составляющую в наиболее тяжелых случаях $O(n^5)$ (некоторые графы, близкие к полным графам).

Приложения алгоритма

На основе эвристики, используемой для проверки изоморфизма графов, построен алгоритм поиска оптимального вложения графов – решения задачи, представляющей собой обобщение задачи поиска в данном графе подграфа, изоморфного другому графу. Модификация алгоритма применима к решению задач проверки изоморфизма ориентированных и взвешенных графов, что позволяет эффективно применять алгоритм к решению задачи дешифрования шифра двойной перестановки [6], являющимся обобщением одной из базовых процедур шифрования данных – шифра перестановки. Численные эксперименты показывают, что число символов в дешифруемом тексте может достигать 10000 при устойчивой работе алгоритма.

Предлагается приложение построенного алгоритма дешифрования шифра двойной перестановки к следующей задаче. По каналу связи от источника к приемнику передается видеоизображение. Необходимо шифровать видеоизображение во избежание утери информации при подключении третьих лиц к каналу связи. При этом необходимо без потери эффективности процедуры дешифрования реализовать шифрование изображения так, чтобы ключ к шифру динамически менялся при передаче кадров видеоизображения по каналу связи без передачи ключа к шифру от источника к приемнику в

явном виде.

Литература

1. Гэри М., Джонсон Д. Вычислительные машины и труднорешаемые задачи // М.: Мир, 1982.
2. Hopcroft J., Wong J. A linear time algorithm for isomorphism of planar graphs // Proceedings of the Sixth Annual ACM Symposium on Theory of Computing, 1974. P.172-184.
3. Luks E.M. Isomorphism of graphs of bounded valence can be tested in polynomial time // Proc. 21st IEEE FOCS Symp, 1980. P.42-49.
4. Hoffmann C.M. Group-Theoretic Algorithms and Graph Isomorphism Lecture Notes in Computer Science (Chapter V), 1982. P.127-138.
5. Цветкович Д. и др. Спектры графов. Теория и применение.// Киев: Наукова думка, 1984.
6. Faizullin R., Prolubnikov A. An Algorithm of the Spectral Splitting for the Double Permutation Cipher. Pattern Recognition and Image Analysis. MAIK, Nauka. Vol. 12, p. 365-375. No. 4, 2002.

Гиперкомплексный анализ числовых последовательностей размерности 2^n

С.Б. Пшеничников, Б.С. Пшеничников

(Москва)

Любая последовательность действительных или комплексных чисел представляется в виде произведения элементов алгебры Клиффорда, являющейся матричным обобщением комплексных чисел. Матрицами размерности $2^n \times 2^n$ представляются $2n$ образующих. Например, последовательность двух действительных чисел r_1, r_2 может быть представлена в виде

$$(r_1 E^{(2 \times 2)} + r_2 e_1^{(2 \times 2)}) \Phi^{(2 \times 2)},$$

$$\text{где } E^{(2 \times 2)} = \begin{vmatrix} 1 & 0 \\ 0 & 1 \end{vmatrix}, e_1^{(2 \times 2)} = \begin{vmatrix} 0 & 1 \\ 1 & 0 \end{vmatrix}, e_2^{(2 \times 2)} = \begin{vmatrix} 0 & 1 \\ -1 & 0 \end{vmatrix}, \Phi^{(2 \times 2)} = \frac{1}{2} (E^{(2 \times 2)}$$

$- e_1^{(2 \times 2)} e_2^{(2 \times 2)})$. Множество этих элементов является кольцом и имеет более интересную алгебраическую структуру по сравнению с представлением числовых последовательностей столбцами (не определена операция умножения). Разработаны алгоритмы разложения клиффордовых чисел, соответствующих числовым последовательностям, в произведения множителей и нахождения идеалов, порожденных базисами, аналогичных базису Грёбнера в полиномиальных идеалах. Например, $p\Phi^{(2 \times 2)} + q$, где

$p = -r_1 e_1^{(2 \times 2)} e_2^{(2 \times 2)}, q = r_2 e_1^{(2 \times 2)} \Phi^{(2 \times 2)}$; $p = r_2 e_1^{(2 \times 2)}, q = r_1 E^{(2 \times 2)} \Phi^{(2 \times 2)}$;
 $p = -r_2 e_2^{(2 \times 2)}, q = r_1 E^{(2 \times 2)} \Phi^{(2 \times 2)}$. Построены алгебры и группы Ли на
 клиффордовых числовых последовательностях и алгоритмы нахождения их
 структурных постоянных. Разработаны общие основы алгебраической
 классификации клиффордовых числовых последовательностей. С помощью
 алгебры проекторов разработан аппарат гиперкомплексного
 кратномасштабного анализа иерархических функций, полученных
 последовательным рекурсивным делением (вейвлеты Хаара, Добеши, В-
 сплайны). Например, проектором является выражение $\frac{1}{2}(E^{(2 \times 2)} + e_1^{(2 \times 2)})$, а

преобразованием Хаара выражение $\frac{1}{2}(E^{(2 \times 2)} + e_2^{(2 \times 2)})$. Полученные
 результаты применены к анализу временных рядов, распознаванию
 точечных конфигураций и сжатию данных.

Работа выполнена в рамках проекта “Алгебраические и комбинаторные
 методы математической кибернетики” Программы фундаментальных
 исследований Отделения математических наук РАН.

Предельные теоремы теории возможностей

Ю.П. Пытьев

(Москва)

Как известно, если $\xi_1, \dots, \xi_n, \dots$ – последовательность взаимно
 независимых копий случайной величины ξ , и существует математическое
 ожидание $E\xi$, то для любого $\varepsilon > 0$ при $n \rightarrow \infty$

$$\text{Pr}(|(\xi_1 + \dots + \xi_n)/n - E\xi| > \varepsilon) \rightarrow 0, \quad (1)$$

и в этом смысле $f_n(\xi_1, \xi_2, \dots) \equiv (\xi_1 + \dots + \xi_n)/n$ сколь угодно точно
 оценивает $E\xi$, если n достаточно велико. Если существует и дисперсия
 $E(\xi - E\xi)^2 = \sigma^2$, то факт сходимости (1), известный как *закон больших
 чисел*, уточняется центральной предельной теоремой, согласно которой при
 $n \rightarrow \infty$ равномерно по $x \in R_1$

$$\text{Pr}\left(\frac{\sqrt{n}}{\sigma} \left(\frac{\xi_1 + \dots + \xi_n}{n} - E\xi\right) < x\right) \rightarrow \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-t^2/2} dt. \quad (2)$$

Прикладной аспект предельных теорем (1) и (2) поясним на примере

оценивания величины $\tau \in R_1$ на основе измерений, выполняемых по схеме

$$\xi_i = \tau_i + \nu_i, \quad i = 1, \dots, n, \quad (3)$$

где ξ_i – результат, ν_i – ошибка i -го измерения τ , $E \nu_i = 0, i = 1, \dots, n$. С увеличением n согласно (1) $f_n(\xi_1, \xi_2, \dots)$ по вероятности сходится к $E \xi = \tau$. Этот эффект уточнения оценивания при повторении *статистически независимых* измерений количественно выражается в уменьшении дисперсии ошибки оценивания: $E(f_n(\xi_1, \xi_2, \dots) - \tau)^2 = \sigma^2/n \xrightarrow{n \rightarrow \infty} 0$, причем при больших n распределение ошибки оценивания $f_n(\xi_1, \xi_2, \dots) - \tau$ близко к нормальному $N(0, \sigma^2/n)$.

Поскольку возможность [1], в отличие от вероятности, принимает значения в ранговой шкале и не имеет частотной интерпретации, рассматриваемые в докладе предельные теоремы теории возможностей существенно отличаются от (1), (2).

Рассмотрим асимптотические при $n \rightarrow \infty$ свойства распределений некоторых функций $f_n(\xi_1, \dots, \xi_n) \equiv \zeta_n$ взаимно независимых нечетких элементов (н. э.) ξ_1, \dots, ξ_n , каждый из которых является копией н. э. ξ . Если $\varphi^\xi(\cdot): X \rightarrow [0,1]$ – распределение¹ н. э. ξ , принимающего значения в X , и $f_n(\cdot, \dots, \cdot): X^n \rightarrow Z$, то распределение $\varphi^{\zeta_n}(\cdot): Z \rightarrow [0,1]$ н. э. ζ_n дается равенством [1]

$$\varphi^{\zeta_n}(z) = \sup \{ \min(\varphi^\xi(x_1), \dots, \varphi^\xi(x_n)) \mid x_1, \dots, x_n \in X, f_n(x_1, \dots, x_n) = z \}, \quad z \in Z. \quad (4)$$

Теорема 1. Пусть $\zeta^{(n)} = \max(\xi_1, \dots, \xi_n)$ и $\zeta_{(n)} = \min(\xi_1, \dots, \xi_n)$, $X = Z = R_1$. Если н. э. $\xi_1, \dots, \xi_n \in R_1$ взаимно независимы и одинаково распределены как н. э. $\xi \in R_1$, то согласно (4) н. э. $\zeta^{(n)}$ и $\zeta_{(n)}$ при любом $n = 1, 2, \dots$ распределены как ξ (см. [1], [2]), т.е.

¹ Значение $\varphi^\xi(x)$ есть возможность равенства $\xi = x$, возможность включения $\xi \in A \subset X$ есть $P(\xi \in A) = \sup_{x \in A} \varphi^\xi(x)$, [1].

$$\varphi^{\xi^{(n)}}(z) = \varphi^{\xi^{(n)}}(z) = \varphi^{\xi}(z), \quad \xi \in R_1, \quad n = 1, 2, \dots \quad \hat{1}$$

В качестве примера применения теоремы 1 рассмотрим задачу оценивания н. э. τ на основе измерений, выполненных по схеме (3). Пусть V_1, \dots, V_n – независимые копии н. э. V , $\varphi^V(\cdot) : R_1 \rightarrow [0, 1]$ – его распределение, $\varphi^\tau(\cdot) : R_1 \rightarrow [0, 1]$ – распределение τ , и н. э. V_1, \dots, V_n, τ взаимно независимы. Если значения τ априори равновозможны, т. е. $\varphi^\tau(t) = 1, t \in R_1$, то имеет место следующий факт.

Теорема 2. Если функция $\varphi^V(\cdot)$ равна единице в нуле, четная, $\varphi^V(x) = \varphi^V(|x|), x \in R_1$, и строго монотонно убывает на $R_+ = [0, \infty)$, то стратегия оценивания $d(\cdot)$, минимизирующая необходимость ошибки оценивания τ , определяется равенством

$$d(\bar{\xi}) = \left(\max_{1 \leq i \leq n} \xi_i + \min_{1 \leq i \leq n} \xi_i \right) / 2, \quad \text{где } \bar{\xi} = (\xi_1, \dots, \xi_n).$$

Нечеткая ошибка $d(\bar{\xi}) - \tau$ оценивания τ посредством $\hat{\tau} = d(\bar{\xi})$ равна $\left(\max_{1 \leq i \leq n} v_i + \min_{1 \leq i \leq n} v_i \right) / 2$, ее распределение $\varphi^{\hat{\tau} - \tau}(z) = \varphi^V(z), z \in R_1$, не зависит от $n = 1, 2, \dots$ (см. [1, 2]). $\hat{1}$

Факты, приведенные в теоремах 1, 2, разительно отличаются от их статистических аналогов.

Рассмотрим асимптотические при $k \rightarrow \infty$ свойства распределений н. э.

$$\zeta_k = (\xi_1 + \dots + \xi_k) / k, \quad \xi_1, \dots, \xi_k, \zeta_k \in R_n, \quad k = 1, 2, \dots \quad (5)$$

Пусть $\Phi(R_n)$ – класс функций $\varphi(\cdot) : R_n \rightarrow [0, 1]$, таких, что для любых $x_0, x_1 \in R_n$, $\lambda_0, \lambda_1 \geq 0$, $\lambda_0 + \lambda_1 = 1$, $\varphi(\lambda_0 x_0 + \lambda_1 x_1) \geq \min(\varphi(x_0), \varphi(x_1))$, $\Psi(R_n)$ – класс всех функций $\psi(\cdot) : R_n \rightarrow [0, 1]$.

Определим оператор $T_k : \Psi(R_n) \rightarrow \Psi(R_n)$ следующим равенством

$$(T_k \psi)(x) = \sup \{ \min(\psi(x_0), \dots, \psi(x_k)) \mid x_0, \dots, x_k \in R_n, \\ x \in \text{co}\{x_0, \dots, x_k\} \},$$

в котором

$$x \in \text{co}\{x_0, \dots, x_k\} \equiv \{ \lambda_0 x_0 + \dots + \lambda_k x_k \mid \lambda_0, \dots, \lambda_k \geq 0, \lambda_0 + \dots + \lambda_k = 1 \}, \\ x \in R_n, \quad k = 1, 2, \dots$$

Определение 1. Последовательность н. э. $\xi_1, \dots, \xi_k, \dots$ назовем сходящейся по распределению к н. э. ζ , если $\varphi^{\xi_k}(x) \xrightarrow{k \rightarrow \infty} \varphi^\zeta(x)$, $x \in R_n$.

Следующий результат является предельной теоремой для распределений ζ_k (5) при $k \rightarrow \infty$.

Теорема 3. Пусть $\xi_1, \dots, \xi_k, \dots$ – последовательность взаимно независимых копий н. э. ξ и $\zeta_k = (\xi_1 + \dots + \xi_k) / k$. Тогда

1. если $\varphi^\xi(\cdot) : R_n \rightarrow [0,1]$ – непрерывная функция, то при $k \rightarrow \infty$ $\varphi^{\zeta_k}(x) \rightarrow (T_n \varphi^\xi)(x)$, $x \in R_n$, т. е. ζ_k при $k \rightarrow \infty$ сходится по распределению к нечеткому элементу ζ , распределение которого $\varphi^\zeta(\cdot) = (T_n \varphi^\xi)(\cdot) \in \Phi(R_n)$, причем

2. если $\varphi^\xi(\cdot) \in \Phi(R_n)$, то $\varphi^{\zeta_k}(x) = \varphi^\xi(x)$, $x \in R_n$, $k = 1, 2, \dots$;

3. $\Phi(R_n)$ – класс предельных при $k \rightarrow \infty$ распределений н. э. ζ_k (5);

4. для того, чтобы функция $\varphi(\cdot) \in \Phi(R_n)$, достаточно, чтобы хотя бы для одного $k = 1, 2, \dots$ и необходимо, чтобы для любого $k = 1, 2, \dots$

$$(T_k \varphi)(x) = \varphi(x), \quad x \in R_n. \quad \uparrow$$

Работа выполнена при финансовой поддержке РФФИ, грант 02--01--00424.

Литература

1. Пытьев Ю.П. Возможность. Элементы теории и применения. // М.: «Эдиториал УРСС», 2000 г., 192 с.
2. Pyt'ev Yu. P. About limiting Theorems in Possibility Theory. // Pattern Recognition and Image Analysis (в печати).

Предельно достижимые возможности при распознавании многомерных сигналов

А.А. Роженцов

(Йошкар-Ола)

В проводимых в том или ином направлении научных исследованиях закономерным является этап, на котором обосновываются пределы получающихся результатов, определяется, какие из них являются принципиально достижимыми, какие – невозможными. При решении задач обработки зашумленных сигналов подобного рода пределы устанавливаются

на базе теории потенциальной помехоустойчивости В.А. Котельникова [1]. Соотношение между достигнутой помехоустойчивостью разработанной информационной системы и ее потенциальной помехоустойчивостью служит степенью совершенства системы. Как следует из [2] единое количественное определение помехоустойчивости информационных систем затруднительно. Поэтому на практике производится оценка помехоустойчивости отдельных звеньев системы, причем алгоритмы работы этих звеньев оптимизируются с позиции принятых критериев качества. В данной работе рассматривается подход к определению помехоустойчивости не разрозненных звеньев информационной системы, а отдельной подсистемы в виде устройства распознавания. Известным считается лишь векторный характер сигналов, а вид самих сигналов и алфавит, алгоритм оптимальной обработки и правило отнесения зашумленного распознаваемого сигнала к одному из классов алфавита обосновываются или определяются.

Рассмотренная проблема потенциальной эффективности распознавания комплекснозначных и гиперкомплексных векторных сигналов решалась с позиции рассмотренной в [3] интерпретации потенциальной помехоустойчивости информационной системы. В качестве меры различия двух сигналов выбрано расстояние между задающими их векторами. Помехоустойчивость распознающей системы характеризовалась вероятностью правильного распознавания $P_{\text{пр}} = 1 - P_{\text{ош}}$, где $P_{\text{ош}}$ – вероятность ошибочного распознавания сигнала. Предполагалось, что величина $P_{\text{пр}}$ одинакова для всех классов распознаваемых сигналов.

В докладе показано, что потенциальная помехоустойчивость обеспечивается при распознавании сигналов из алфавита в виде полного семейства симплексных сигналов. Анализ процесса распознавания зашумленных симплексных сигналов показал сильную зависимость вероятностей правильного распознавания от преобразований вращения и сдвига начальных точек. Поэтому с практических позиций при обработке комплекснозначных сигналов значительно больший интерес для построения помехоустойчивых систем распознавания представляют семейства элементарных контуров, являющихся ортогональными сигналами. По эффективности распознавания они незначительно проигрывают симплексным. Однако получающиеся результаты распознавания инвариантны к линейным преобразованиям элементарных контуров, а различие в вероятностях $P_{\text{пр}}$ по сравнению с симплексными контурами уменьшается с ростом размерности k .

В работе решена задача синтеза симплексных кватернионных сигналов. Значения предельно достижимых вероятностей их правильного распознавания при одних и тех же размерностях сигналов и входных

отношений сигнал/шум практически совпадают с такими же вероятностями для комплекснозначных сигналов. Алфавит классов E_q эталонных кватернионных сигналов, обеспечивающий получение предельно достижимых вероятностей $P_{пр}$, состоит из полного семейства симплексных кватернионных сигналов, полученных на базе полного семейства элементарных сигналов. Однако кватернионы, входящие в состав элементарных кватернионных сигналов, имеют ненулевую вещественную часть и, как следствие, полученные комплексные сигналы не могут быть интерпретированы в трехмерном пространстве.

Таким образом, в работе предложена методика синтеза алфавитов симплексных комплексных и гиперкомплексных сигналов на базе элементарных контурных и кватернионных сигналов, обеспечивающих максимально достижимые вероятности правильного распознавания сигналов алфавита, получены потенциально достижимые характеристики правильного распознавания сигналов.

Работа выполнена при финансовой поддержке РФФИ, проекты № 01-01-00298, № 03-01-06550

Литература

1. Котельников В.А. Теория потенциальной помехоустойчивости. Госэнергоиздат, 1956.
2. Харкевич А.А. Борьба с помехами. – М.: Наука, гл. ред. Физико-математическая литература. 1965.
3. Филиппов Л.И. Теория передачи дискретных сигналов: Учебное пособие для вузов.-М.: Высшая школа, 1981.
4. Фурман Я.А., Кревецкий А.В., Передреев А.К., Роженцов А.А., Хафизов Р.Г., Леухин А.Н., Егошина И.Л. Введение в контурный анализ и его приложения к обработке изображений и сигналов. – М.: Физматлит, 2002, 592с.

Метод предварительной селекции признаков

О.В. Сенько, А.В. Кузнецова

(Москва)

Современные клинические исследования нередко включают в себя измерение разнообразных биомедицинских показателей, общее число которых может достигать нескольких сотен и значительно превышать число наблюдаемых пациентов. Нередко целью таких исследований является решение задач диагностики и прогноза, которые могут быть сформулированы в виде задач распознавания образов. Однако прямое использование существующих методов оказывается слишком трудоемким и неэффективным из-за высокой размерности данных и значительной доли

признаков, не имеющих диагностической или прогностической ценности. Поэтому задача селекции признаков и формирование оптимального для распознавания информативного поднабора является особенно актуальной.

Существуют различные подходы к отбору признаков. Одной из возможностей является поиск набора с помощью пошаговых или генетических методов, дающего максимальную точность распознавания на обучающей информации. Общее число признаков, включаемых в набор, при этом может быть оптимизировано путем максимизации точности прогноза на контрольной выборке или в режиме скользящего контроля, а также с помощью штрафующего за возрастание сложности критерия Akaike[1]. Основными недостатками методов, основанных на максимизации точности прогноза, являются их неустойчивость к сравнительно небольшим изменениям в обучающей информации, случайное попадание в набор полностью неинформативных признаков и сравнительно высокую трудоемкость. Первые два недостатка усугубляются при уменьшении объема исходной обучающей информации.

Более осторожным подходом является включение в информативный набор только признаков со статистически доказанной индивидуальной прогностической способностью. Недостатком такого подхода является возможность выпадения из набора признаков, чья информативная способность проявляется только в комбинации с другими признаками. Нами был предложен подход к селекции признаков, основанный на поиске в многомерном пространстве потенциальных прогностических признаков множества статистически достоверных закономерностей невысокой размерности. При этом в информативный набор включаются признаки, описывающие закономерности. Предусматривается также дополнительный анализ и селекция признаков исследователем, которой экспертом в данной области.

Предложенный подход был использован при решении задач прогноза динамики после травматической депрессии, диагностик ишемического или геморрагического инсульта, прогноза рецидива миомы матки. Работа выполнена при поддержке РФФИ (гранты 02-07-90134, 02-07-90137, 00-01-00650, 02-01-00558)

Литература

1. C. Chatfield Model Selection, Data Mining and Model Uncertainty.// Proceedings of the 18th International Workshop on Statistical Modelling, 2003, Leuven, Belgium, p.79-84.
2. Sen'ko O.V., Kuznetsova A.V., Echin A.. The method of data analysis based on partitioning.// Proceedings in Comput. Statistics. Short Commun. and Posters. COMPSTAT, 2000, p.259-260.
3. Sen'ko O.V. The Method of Dependencies Description with the Help of Optimal Multistage Partitioning// Proceedings of the Conference CSIT ,

- Yerevan, Armenia, pp.167-169, 2001.
4. A.M.Jackson, A.V.Ivshina, O.Senko, A.Kuznetsova, A.Sundan, M.A.O'Donnel,S.Clinton, A.B.Alexandroff, P.J.Selby, K.James and V.A.Kuznetsov (1998)Prognosis of Intravesical Baccilus Calmette –Guerrin Therapy for Superficial Bladder Cancer by Immunological Urinary Measurements : Statistically Weighted Syndromes Analysis// Journal of Urology.v.159, pp. 1054-1063.

О построении корректных алгоритмов вычисления оценок как задаче условной оптимизации

А.Ю. Сметанин
(Москва)

Исследована задача построения алгоритма вычисления оценок (АВО), не делающего ошибок на данной выборке, без использования методов алгебраического замыкания.

Рассмотрена задача распознавания

$$Z = \{I_0, \tilde{S}^q\}$$

со стандартной обучающей информацией:

$$I_0 = \{S_1, \dots, S_m, \tilde{\alpha}(S_1), \dots, \tilde{\alpha}(S_m)\},$$

$$S_i = (a_{i1}, \dots, a_{in}), \quad i = 1, 2, \dots, m,$$

$$a_{ij} \in M_j, \quad j = 1, 2, \dots, n.$$

и конечной выборкой:

$$\tilde{S}^q = (S^1, \dots, S^q), \quad S^i = (b_{i1}, \dots, b_{in}), \quad i = 1, \dots, q,$$

Информационные векторы для конечной выборки предполагаются известными. В общем случае АВО выглядят так (обозначения соответствуют принятым в [1]):

$$\Gamma_j^1(S) = \frac{1}{Q_1} \sum_{S \in \tilde{K}_j} \sum_{\tilde{\omega} \in \{\tilde{\omega}_A\}} \gamma(S_i) p(\tilde{\omega}) B(\tilde{\omega} S_i, \tilde{\omega} S, \tilde{\varepsilon})$$

$$\Gamma_j^0(S) = \frac{1}{Q_0} \sum_{S \in \tilde{K}_j} \sum_{\tilde{\omega} \in \{\tilde{\omega}_A\}} \gamma(S_i) p(\tilde{\omega}) \bar{B}(\tilde{\omega} S_i, \tilde{\omega} S, \tilde{\varepsilon})$$

где Γ_j – оценка объекта S по j -му классу, ω – характеристический булевский вектор опорного множества, $w^i = \gamma(S_i)$ – веса обучающих объектов, $w_j = p_j$ – веса признаков, B – функция близости, $\bar{B} = 1 - B$.

Предложен подход к построению алгоритма, не делающего ошибок на данной выборке, путем изменения только весов признаков и весов объектов. Это эквивалентно исследованию системы неравенств

$$\left\{ \begin{array}{l} \Gamma_1 > c_2 \\ \dots \\ \Gamma_T > c_2 \\ \Gamma_{T+1} < c_1 \\ \dots \\ \Gamma_Q < c_1 \end{array} \right\},$$

где $Q = ql$, $T < Q$, а индекс $i = 1, 2, \dots, Q$ соответствует некоторой нумерации двумерного массива $u = 1, 2, \dots, l$, $v = 1, 2, \dots, q$, $\Gamma_i = \Gamma_u(S_v)$, с целью выделения максимальной совместной подсистемы.

Построение алгоритма сведено к решению задачи условной оптимизации – сначала находится решение оптимизационной задачи, такой, чтобы все решения исходной задачи были и ее решениями, а затем среди найденных решений итеративно выбираются те, которые являются решениями исходной задачи.

Рассмотрена задача условной оптимизации:

$$\left\{ \begin{array}{l} f(w^1, \dots, w^m, w_1, \dots, w_n) \Rightarrow \max \\ \Gamma_{T+1} < c_1 \\ \dots \\ \Gamma_Q < c_1 \end{array} \right\},$$

где $f(w_1, \dots, w_m, w_1, \dots, w_n)$ – некий функционал. При удачном выборе функционала решение исходной задачи можно свести к решению оптимизационной задачи. Подтверждением тому может послужить следующий пример:

$$f(w^1, \dots, w^m, w_1, \dots, w_n) = \sum_{i=1}^T \text{sgn}(\Gamma_i - c_2).$$

Для системы с таким функционалом в случае если $\max f = T$, то

соответствующее решение $W^{(0)} = (w^{1(0)}, \dots, w^{m(0)}, w_1^{(0)}, \dots, w_n^{(0)})$, очевидно, является решением исходной задачи. Если $\max f < T$, то исходная система несовместна.

Подробно рассмотрены случаи, когда в качестве систем опорных множеств выбраны системы, часто используемые в прикладных задачах [1, 2] – система одноэлементных подмножеств $\{1\}, \{2\}, \dots, \{n\}$ конечного подмножества натуральных чисел $\{1, 2, \dots, n\}$, система из одного элемента $\{(1, 2, \dots, n)\}$, а также вариант, в котором системой опорных множеств является система всех k -элементных подмножеств конечного подмножества натуральных чисел $\{1, 2, \dots, n\}$.

Описан эвристический метод итеративного построения такого алгоритма, основанный на принципе построения жадных алгоритмов. Однако поскольку обрабатываемое множество не является матроидом, то по теореме Радо – Эдмондса [4] он может приводить к неоптимальному выбору.

В алгебре замыканий вычислительная сложность зависит от начальных описаний. Предложенный метод в определенных случаях позволяет на начальном этапе выбирать веса признаков и веса объектов таким образом, чтобы добиться построения удачных алгоритмов, поэтому его можно рассматривать как предварительный этап при построении корректных алгоритмов в алгебраических замыканиях [3].

Литература

1. Журавлев Ю.И. Корректные алгебры над множествами некорректных (эвристических) алгоритмов. II // Кибернетика. 1977. № 6. С. 21-27.
2. Журавлев Ю.И. Корректные алгебры над множествами некорректных (эвристических) алгоритмов. III // Кибернетика. 1978. № 2. С. 35-43.
3. Журавлев Ю.И., Исаев И.В. Построение алгоритмов распознавания, корректных для данной контрольной выборки // ЖВМ и МФ. 1979. Т. 19, № 3. С. 726-738.
4. Edmonds J. Matroids and the greedy algorithm // Math. Program. 1971. 1. С. 127-136.

Формирование поверхностей уровня по векторному полю

В.А. Стадников, С.Н. Чуканов

(Омск)

В работе рассмотрена задача построения поверхности, нормальный орт которой в каждой точке совпадает с касательным ортом к интегральной кривой заданного векторного поля динамической системы в этой точке.

Плоская кривая, как поверхность в R^2 , может быть формализована в форме [3, 7]: $C(p, t) = [x(p, t), y(p, t)]^T$, где p параметризует кривую, t - семейство кривых (время). Эволюция кривых соответствует уравнению

теплопроводности [5, 7]: $C_t(p, t) = C_{pp}(p, t); C(p, 0) = C_0(p)$.

Плоская кривая C эволюционирует согласно соотношению

$$C_t = \beta N;$$

для заданной функции β проекции вектора скорости эволюции кривой на единичный вектор направления нормали N к этой кривой.

Пусть кривая C представляется (неявно) скалярной функцией уровня u , то есть C совпадает с набором точек $u(x(p, t), y(p, t))|_{t=const} = const$ [4, 6, 8]. Функция u должна эволюционировать согласно соотношению [4]:

$$u_t = \beta |\nabla u|$$

где функция β вычисляется на уровнях множествах.

Поверхность S в R^3 может быть задана параметрами u, v и вектором: $r_S = r_S(u, v) = (x(u, v), y(u, v), z(u, v)); r_S \in S$. Кривая $u=u(t), v=v(t)$ определяет кривую $r_C = r(u(t), v(t))$, лежащую на поверхности $r_C \in S$. Ее вектор скорости $dr_C(t)/dt$ имеет вид [1]:

$$dr_C(t)/dt = r_{C_u} du/dt + r_{C_v} dv/dt; r_{C_u} = \partial r_C / \partial u; r_{C_v} = \partial r_C / \partial v;$$

Единичный вектор нормали к поверхности задается соотношением:

$$N_S = [r_u, r_v] / |[r_u, r_v]|.$$

Если поверхность задана параметрами $u = x; v = y$:

$$r_S = r_S(x, y) = (x, y, z(x, y)); z = f(x, y);$$

$$dr_C(t)/dt = (r_{C_x} + f_x r_{C_z}) dx/dt + (r_{C_y} + f_y r_{C_z}) dy/dt;$$

то [1]:

$$(r_S)_x = (1, 0, f_x); (r_S)_y = (0, 1, f_y); [(r_S)_x, (r_S)_y] = (-f_x, -f_y, 1);$$

и единичный вектор нормали к поверхности:

$$N_S = [r_{S_x}, r_{S_y}] / |[r_{S_x}, r_{S_y}]| = (-f_x, -f_y, 1) / (1 + f_x^2 + f_y^2)^{-0,5}.$$

Поверхность S должна эволюционировать согласно соотношению

$$(r_S)_t = \beta N_S;$$

где $\beta(x, y)$ - функция, зависящая от точки на поверхности.

Пусть задана динамическая система с каноническими соотношениями:

$dx/dt = f(x); x \in R^n; f \in R^n$; которые характеризуют векторное поле: $\xi = f(x)$. Рассмотрим кривую C , задаваемую вектором $x(t)$; каждой точке кривой сопоставим касательный вектор ξ . Касательный орт векторного поля в заданной точке $v_0 = \xi / |\xi| = f(x) / |f(x)|$.

Построим поверхность S , нормальный орт которой в каждой точке совпадает с касательным ортом к интегральной кривой заданного векторного поля в этой точке.

Для этого построим сопровождающей репер, связанный с интегральной кривой векторного поля. Выпишем последовательность векторов:

$\xi(t); d\xi(t)/dt; d^2\xi(t)/dt^2$ в рассматриваемой точке кривой, в которой эти 3 вектора линейно независимы. Построим соприкасающиеся плоскости R_1 и R_2 , проходящие через заданную точку и $\xi(t); d\xi(t)/dt; d^2\xi(t)/dt^2$: $R_1 \subset R_2$. Далее, построим ортонормированный сопровождающий репер, связанный с каждой точкой кривой, с ортами v_0, v_1, v_2 : $v_0 = \xi / |\xi|$; $(v_1 \in R_2) \wedge (v_1 \in R_1); (v_2 \in R_2)$. Орт v_0 – касательная к кривой; v_1, v_2 – нормали к кривой. Для определения ортов v_1, v_2 по производным $d\xi(t)/dt; d^2\xi(t)/dt^2$ можно воспользоваться следующими соотношениями:

$$d\xi(t)/dt = d|\xi|/dt v_0 + |\xi| \kappa_1 v_2;$$

$$d^2\xi(t)/dt^2 = d^2|\xi|/dt^2 v_{d\xi(t)/dt} + d|\xi|/dt \kappa_2 v_2;$$

Коэффициенты κ_1, κ_2 (кривизны кривой) определяются из условия нормирования ортов.

Для производных $dv_0/dt, dv_1/dt, dv_2/dt$ ортов сопровождающего репера кривой в евклидовом пространстве R^3 запишем соотношения Френе-Серре [2]: $dv_0/dt = \kappa_1 v_1; dv_1/dt = -\kappa_1 v_0 + \kappa_2 v_2; dv_2/dt = -\kappa_2 v_1$.

Исходя из соотношений Френе-Серре получим способ определения ортов v_1, v_2, v_3 и $\kappa_1, \kappa_2, \kappa_3$ по индукции:

$$\kappa_1 = |dv_0/dt|; v_1 = \kappa_1^{-1} dv_0/dt;$$

$$\kappa_2 = |dv_1/dt + \kappa_1 v_0|; v_2 = \kappa_2^{-1} (dv_1/dt + \kappa_1 v_0);$$

Для построения требуемой поверхности, нормальный орт которой в заданной точке пропорционален r_{S_t} : $r_{S_t} = \beta N_S$; совпадает с касательным

ортом к интегральной кривой векторного поля в этой точке: $\nu_0 = \xi / |\xi|$; должны выполняться условия:

$$N_S = \nu_0; (r_S)_t = \beta N_S = \bar{\beta} \xi; \bar{\beta} = \beta / |\xi|; N_S \perp \nu_1; N_S \perp \nu_2.$$

Построение поверхностей, соответствующих векторным полям динамических систем, имеет значение для формирования инвариантов, по отношению к группам преобразований (например, аффинной группы [3]), характеризующих эти поверхности при их деформации.

Работа поддержана грантами РФФИ 01-01-00303а и 01-07-90003в.

Литература

1. Дубровин Б.А., Новиков С.П., Фоменко А.Т. Современная геометрия: методы и приложения. - М.: Наука, 1986.- 760 с. Риманова геометрия и тензорный анализ. - М.: Наука, 1967. - 664 с.
2. Рашевский П.К. Риманова геометрия и тензорный анализ. - М.: Наука, 1967. - 664 с.
3. Calabi, E., Olver P.J., Tannenbaum A. Affine geometry, curve flows, and invariant numerical approximations // Adv. in Math. 124, 1996.- pp. 154-196.
4. Caselles V., Kimmel R., Sapiro G. Geodesic Active Contours // International Journal of Computer Vision 22(1), 1997.- pp. 61-79.
5. Grayson M. The heat equation shrinks embedded plane curves to round points // J. Differential Geometry, 26, 1987.- 285-314.
6. Osher S. J., Sethian J. A. Fronts propagation with curvature dependent speed: Algorithms based on Hamilton-Jacobi formulations // Journal of Computational Physics 79, 1988.- pp. 12-49.
7. Sapiro G., Tannenbaum A. On affine plane curve evolution // Journal of Functional Analysis, 119, 1994.- pp. 79-120.
8. Sethian J.A. A review of recent numerical algorithms for hypersurfaces moving with curvature dependent speed // J. Differential Geometry 31, 1989.- pp. 131-161.

Прогноз и управление в авторегрессионных моделях

В.В. Стрижов, В.В. Шакин

(Москва)

Векторные авторегрессионные модели и модели на основе одновременных уравнений являются эффективными инструментами макроэкономического анализа. Ранее, см. [1-3], была построена модель краткосрочного прогноза основных макроэкономических показателей российской экономики с использованием системы линейных одновременных уравнений. В данной работе для прогноза используется векторно-авторегрессионная модель, составленная таким образом, что значения прогнозной функции зависят не только от экзогенных, сценарных

воздействий, но и, в частности, от целевого управления. Новая модель позволяет найти оптимальные управляющие воздействия и спрогнозировать состояние объекта управления при оптимальном управлении.

Прямая задача нахождения состояния $Y = Y_t$ объекта управления по экзогенным переменным $X = X_t$, согласно векторной авторегрессионной

модели, имеет вид $Y_t = \sum_{\tau=0}^r (A_\tau Y_{t-\tau} + B_\tau X_{t-\tau}) + M + \varepsilon_t$, где Y_t –

состояние объекта управления в момент времени t , описываемое набором эндогенных переменных; X_t – управляемые и неуправляемые внешние воздействия на объект управления в момент времени t , описываемые набором экзогенных переменных; t – дискретное время $t = 1, \dots, t_0$ и $\tau = 0, \dots, r < t_0$ – временной лаг. В уравнение включены вектор M –

регрессионное среднее и вектор ε_t – регрессионный остаток, в общем различный в каждый момент времени. Пусть состояние объекта управления описано p действительными переменными, а внешние воздействия описаны q действительными переменными. Тогда треугольная матрица $A \in R^{p \times p}$, матрица $B \in R^{p \times q}$ и векторы $Y, M, \varepsilon \in R^p, X \in R^q$.

Для прогноза состояния объекта при различных управляющих воздействиях, экзогенные переменные, элементы вектора X , разделяются на управляемые переменные U и переменные внешнего воздействия Z . Соответственно матрица регрессионных коэффициентов B разделяется на присоединенные матрицы $C | F$.

Полученная приведенная форма уравнения векторной авторегрессии

$$Y_t = (I - A_0)^{-1} \left(C_0 U_t + F_0 Z_t + \sum_{\tau=1}^r (A_\tau Y_{t-\tau} + C_\tau U_{t-\tau} + F_\tau Z_{t-\tau}) + M + \varepsilon_t \right)$$

для получения краткосрочного прогноза состояния по заданному управлению редуцируется до выражения $Y_t = G_r U_t + H_{t,r}$.

Для решения задачи оптимального прогноза редуцированное выражение обращается, $U_t = G_r^+ (Y_t - H_{t,r})$, где псевдообратная матрица G_r^+ получена с помощью сингулярного разложения.

Задача нахождения оптимального управления ставится следующим образом. Для заданной предыстории поведения объекта управления и заданного сценария внешних воздействий Z_{t_0}, \dots, Z_{t_n} требуется найти такую

последовательность управляющих воздействий U_{t_0}, \dots, U_{t_n} , при ограничениях $U_t \in \Delta U_t$, которая приводила бы объект управления из начального состояния Y_{t_0} в достижимое целевое состояние \bar{Y}_{t_n} за заданное число шагов при минимальной стоимости управления $C^*(U_{t_0}, \dots, U_{t_n})$.

В основу процедуры оптимизации управления положен принцип оптимальности Р. Беллмана: любое оптимальное управление может быть образовано только оптимальными управляющими воздействиями на каждом шаге. Иначе, при любом состоянии системы перед очередным шагом необходимо выбирать управление так, чтобы стоимость управления на данном шаге и стоимость управления на всех последующих шагах была минимальной.

Под действием управления U_t объект принимает состояние $Y_t = h_t(U_t, Y_{t-1}) = G_r U_t + H_{t,r}$, причем стоимость управления на каждом шаге определяется как $f(U_t, Y_{t-1})$.

Рекуррентное уравнение динамического программирования выражает стоимость $C_t(Y)$ условного оптимального управления, начиная с t -го шага до первого шага t_0 через уже известную функцию $C_{t+1}(Y)$:

$$C_t(Y) = \min_{U_t \in \Delta U_t} [f(U_t, Y_{t-1}) + C_{t+1}(h_t(U_t, Y_{t-1}))]$$

Этой стоимости соответствует условное оптимальное управление U_t на шаге t .

Таким образом, сначала производится условная оптимизация последнего шага t_n для множества состояний Y_{t_n-1} таких, что $Y_{t_n} = h(U_{t_n}, Y_{t_n-1})$ при $U_{t_n} \in \Delta U_{t_n}$, вычисляется условная стоимость $C_{t_n}(Y) = \min_{U_{t_n} \in \Delta U_{t_n}} f(U_{t_n}, Y_{t_n-1})$ и находится оптимальное управление U_{t_n} .

Далее производится условная оптимизации для всех шагов $t: t_n > t > t_0$.

Так как начальное состояние объекта управления Y_{t_0} известно, то искомая величина $C^* = C^*(U_{t_0}, \dots, U_{t_n}) = C_1(Y_{t_0})$.

Были проведены численные эксперименты с использованием ежеквартальных измерений двенадцати основных показателей состояния российской экономики за 1994–2002 годы. Получено множество различных траекторий Y_{t_0}, \dots, Y_{t_n} , позволяющих достичь целевого состояния \bar{Y}_{t_n}

объекта управления. Найдены оптимальные траектории для заданных функций стоимости управления. Выяснилось, что не всегда максимальная стоимость управления приводит к наискорейшему достижению целевого состояния.

Работа поддержана грантом РФФИ 00-01-00197.

Литература

1. Aivazian S. A., Borisova S. V., Lakalin E. A., Makarov V. L. Econometric Modelling of the Russian Economy. – Acta Applicandae Mathematicae, vol. 75(2003), №1.
2. <http://www.osp.ru/os/1997/03/73.htm>
3. Макаров В. Л. Вычислительная модель российской экономики (RUSEC). – Препринт WP/99/069, М.: ЦЭМИ РАН, 1999 г.

Аналитическое описание зашумленных исходных сигналов по функциям Сонина-Лагерра и получение их первых производных

Р.К. Тетуев

(Пушино)

Имея приближенное с заданной точностью представление некоторого сигнала в виде разложения в ряд по системе ортогональных функций, возможно проводить достаточно глубокий анализ применительно ко многим приложениям. Однако полезно в каждом частном случае иметь возможность выбирать наиболее подходящую систему ортогональных функций из нескольких возможных. Таким образом, учитывая специфику сигнала, можно быстро получить его аналитическое описание с требуемой точностью наиболее коротким отрезком ряда, а также и его нескольких производных. При этом устойчивость полученных результатов сохраняется при довольно высоком уровне шума в исходном сигнале.

Часто в различных приложениях мы встречаемся с необходимостью анализа сигнала, для которого характерно затухание в конце интервала наблюдения. Учитывая эту специфику, было решено воспользоваться здесь системой ортогональных функций Сонина-Лагерра с введенным масштабным параметром m [1]. Явная формула ортогональных и нормированных функций с введенным m имеет вид:

$$l_n^\alpha(mt) = \sqrt{(mt)^\alpha e^{-mt}} \sum_{k=0}^n C_{n+\alpha}^{n-k} \frac{(-mt)^k}{k!}$$

После нахождения коэффициентов по известной формуле, исследуемый процесс может быть записан в следующем виде:

$$f(t) = \sum_{n=1}^N A_n(m) l_n^\alpha(mt),$$

где N – глубина разложения, m – параметр масштабирования.

Проведена работа по квазиоптимальному представлению такого сигнала рядом по ортогональным функциям Сонина-Лагерра. На рис. 1 дано приближение зашумленного сигнала для исходной функции

$$f(t) = 5 \sin(2t) e^{-t/2}$$

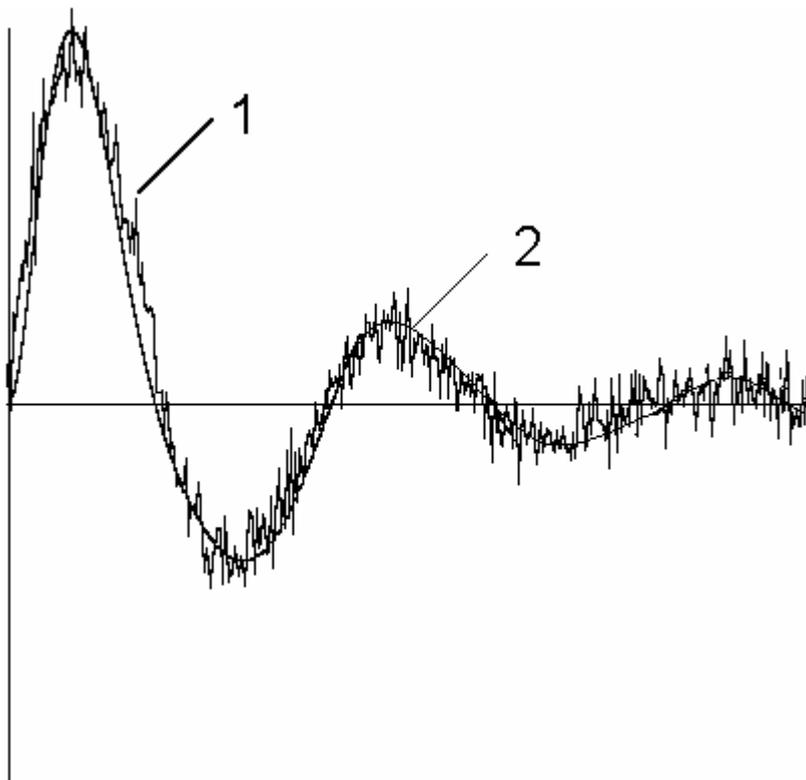


Рис. 1. Приближение сигнала с дисперсией шума $D=0.32$ при $N=30$, $m=1$, $\alpha=0.7$ (где 1 – зашумленный исходный сигнал, 2 – его аналитическое приближение).

Уже при небольшой глубине разложения (14-17 членов ряда) и высоком уровне шума (10%-20%) получены хорошие приближения исходной функции. Используя в дальнейшем лишь имеющиеся коэффициенты разложения, и воспользовавшись выведенной формулой, были получены в аналитической форме первая, вторая и последующие производные. При

незначительном изменении глубины ряда разложения, изменяя параметр альфа и параметр масштабирования, можно получить устойчивые (относительно уровня шума) представления не только функции, но и первых ее производных до третьего порядка и т. д.

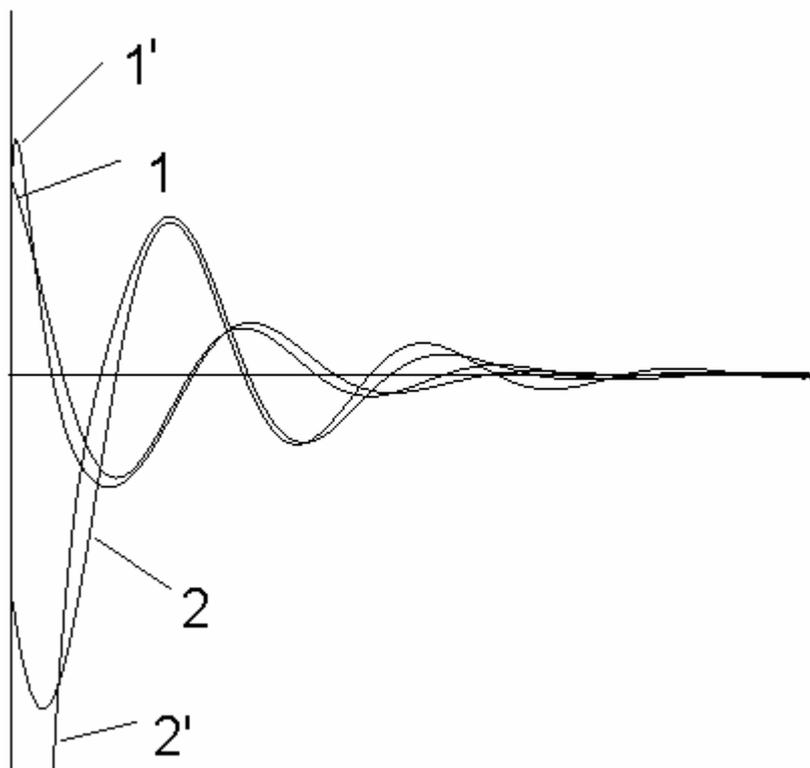


Рис. 2. Первые производные и полученные приближения.

Проведение исследования позволяют сформулировать следующие важные выводы:

1. Возможность получения быстрого и точного аналитического представления сглаженного сигнала.
2. Возможность получения аналитического представления производных сглаженного сигнала при использовании лишь коэффициентов разложения исходного сигнала.
3. Возможность варьирования нескольких параметров ортогональных функций разложения для достижения квазиоптимального представления сигнала и его первых производных.

Проводимые исследования выполняются при финансовой поддержке РФФИ (номера проектов: 01-07-97060, 01-07-90317, 01-01-00894).

Литература

1. Дедус Ф.Ф., Махортых С. А., Устинин М. Н., Дедус А. Ф. Обобщенный спектрально-аналитический метод обработки информационных массивов. // Машиностроение. Москва, 1999. С. 81.

Динамическая диагностика функций и состояний управляемых систем

А.В. Тимофеев
(Санкт-Петербург)

Введение

Важным объектом диагностики являются управляемые динамические системы (ДС). К ним относятся роботы, летательные и подводные аппараты, компьютерные сети и т.п. [1,2]. Медицинская диагностика заболеваний также может осуществляться на основе моделей ДС пациента. Анализ неисправностей управляемых ДС играет важную роль при контроле правильности их функционирования, технической диагностике состояний и локализации возможных дефектов (неисправностей) с целью их устранения. В общем случае этот анализ не сводится к так называемому “функциональному диагностированию” в реальном времени, а подразумевает также формальное определение и априорное оценивание критериев правильности функционирования управляемой ДС, классификацию динамических моделей неисправностей, оценку их допустимых границ (допусков) и синтез дефектоустойчивого управления.

Прямые и обратные модели динамики управляемых систем

Управляемые ДС, поведение которых $x(t)$ зависит от начального состояния x_0 , управления $u(t)$, параметров ξ и внешних возмущений $\pi(t)$, описываются векторным дифференциальным уравнением вида

$$\dot{x} = F(x, u, \xi) + \pi, \quad x(t_0) = x_0, \quad t \in [t_0, t_T]. \quad (1.1)$$

Прямая модель динамики (ПМД) в форме Коши (1.1) эквивалентна обратной модели динамики (ОМД) вида

$$u = U(x, \dot{x} - \pi, \xi), \quad (x, \dot{x}) \in P_F, \quad x(t_0) = x_0, \quad t \in [t_0, t_T]. \quad (1.2)$$

на инвариантном подпространстве P_F [1-4]. Она позволяет по заданному программному движению (ПД) $x(t) = x_p(t)$ и вектору параметров $\xi \in Q_\xi$ найти в аналитическом виде программное управление (ПУ) $u(t) = u_p(t)$ как решение уравнения (1.1) при $x(t) = x_p(t)$ и $\pi(t) = 0$. ПМД и ОМД играют

важную роль при диагностике функций и состояний управляемых ДС и синтезе дефектоустойчивого управления в нестационарных и неопределённых условиях [5-8].

Функциональная диагностика и классификация дефектов

Цель управления заключается в том, чтобы перевести ДС (1.1) из заданного начального состояния x_0 в желаемое конечное состояние x_p . Для достижения этой цели нужно построить ПД и синтезировать ПУ, которые гарантируют выполнение заданных граничных условий вида

$$x_p(t_0) = x_0, x_p(t_T) = x_T, T \equiv t_0 - t_T \leq \infty \quad (2.1)$$

ДС подвергается воздействию возмущений и дефектов. Поэтому идеальная цель ПУ (точное осуществление ПД) заменяется целевым неравенствам вида

$$\|E(t)\| \leq \varepsilon, t \in [t_0, t_T], \quad (2.2)$$

где $E(t) = x(t, x_0, u, \pi) - x_p(t)$ - динамическая ошибка (переходной процесс), а ε - требуемая точность. Нарушение целевого неравенства (2.2) говорит о неисправности управляемой ДС при заданном управлении.

Критерием обнаружения неправильного функционирования (неисправности) ДС может служить диагностический предикат вида

$$d_p(E(t)) = \begin{cases} 1, & \text{если } \|E(t)\| > \varepsilon, \\ 0, & \text{если } \|E(t)\| \leq \varepsilon, \end{cases} \quad (2.3)$$

который разбивает n -мерное пространство состояний управляемой ДС на два класса: Ω_I - множество неисправных состояний и Ω_{II} - множество исправных состояний.

Начальные, параметрические, внешние и инструментальные дефекты в ДС задаются границами своих возможных значений (допусками) вида

$$\|E(t_0)\| \leq c_0, \|\xi - \hat{\xi}\| \leq c_\omega \leq \text{diam } Q_\xi, \|\pi(t)\| \leq c_\pi, \|x - \hat{x}(t)\| \leq c_\Delta, \quad (2.4)$$

где $\hat{\xi}$ - оценка неизвестных параметров ξ , а \hat{x} - измеренное датчиками реальное состояние x , используемые в алгоритме управления ДС [6].

Критерии правильности функционирования и алгоритмы дефектоустойчивого управления

Определим показатель неправильности функционирования ДС как лебегову меру множества моментов нарушения целевых неравенств (2.1), т.е.

$$w_\varepsilon = \text{mes} \{t : \|E(t)\| > \varepsilon, t \in [t_0, t_T]\}. \quad (3.1)$$

Получены двухсторонние оценки этого показателя, характеризующего

общее время неправильного функционирования ДС, в зависимости от используемого алгоритма управления и допусков (2.4) на дефекты.

На основе методов робастного, инвариантного и адаптивного управления предложенных в [2-4], синтезированы алгоритмы дефектоустойчивого управления ДС в условиях неопределённости [6,11].

Методы одно- и мульти-агентной диагностики состояний

Для автономных ДС разработаны методы диагностики состояний, основанные на синтезе полиномиальных распознающих функций и нейронных сетей по экспериментальным диагностическим базам данных [1,5,10]. Эти методы успешно применялись в задачах медицинской диагностики, оценки эффективности лечения и прогнозирования состояний.

Разработаны принципы и алгоритмы мульти-агентной диагностики для группы (коллектива) автономных ДС (в частности, для мульти-агентных робототехнических систем и телекоммуникационных сетей).

Работа выполнена при поддержке грантов РГНФ № 03-06-12019в, РФФИ № 03-01-00224 и Минпромнауки РФ № 37.029.11.0027.

Литература

1. Тимофеев А.В. Адаптивные робототехнические комплексы. - Л.: Машиностроение, 1988, 332 с.
2. Тимофеев А.В., Экало Ю.В. Системы цифрового и адаптивного управления роботом. - СПб.:Изд-во СПбГУ, 1999, 248 с..
3. Попов Е.П., Тимофеев А.В. Управляемость на подпространстве и адаптивные модальные регуляторы. - Доклады АН СССР, 1983, т.273, № 5, с. 1070-1073
4. Тимофеев А.В. Синтез адаптивных регуляторов с помощью функций Ляпунова. - Доклады Академии наук СССР, 1984, т. 237, № 2, с. 276-279.
5. А.В.Тимофеев Мульти-агентное и интеллектуальное управление сложными робототехническими системами. - Юбилейный сборник "Теоретические основы и прикладные задачи интеллектуальных информационных технологий", посвящённый 275-летию РАН и 20-летию СПИИ РАН-СПб., - СПИИ РАН, 1999, с.71-81.
6. Тимофеев А.В. Функциональный анализ неисправностей динамических систем и дефектоустойчивость стабилизирующего управления. - Доклады АМАН, 2002, т.6, № 1, с.62-71.
7. Timofeev A.V. Neural Control, Multi-Agent Navigation and Virtual Reality Models of Robots. - CD-ROM Proceedings of NOLCOS'01 5-th IFAC Symposium "Non-Linear Control Systems", Saint-Petersburg, July 4-6, 2001.
8. Тимофеев А.В. Управляемость, робастность и обратимость динамических систем. - Доклады Академии наук, 1998, т. 359, № 2, с. 171-174.
9. Тимофеев А.В., Шибзухов З.М., Шеожев А.М. Проектирование и

- обучение мульти-агентных диагностических систем. - Труды Первой Международной конференции по мехатронике и робототехнике МиР'2000 (Санкт-Петербург, 29 мая -2 июня 2000 г.), том 2, с.342-345.
10. A.V.Timofeev. Tools for Functional Analysis of Faults and Methods of Fault-Stable Motion Control. - International Scientific Journal "Nuclear Instruments and Methods in Physics Research", Elsevier Science, 2003.
 11. A.V.Timofeev. Physical Diagnostics and Fault Relevant Feedback Control. - Proceedings of the International Conference "Physics and Control" (PhysCon'03), Saint-Petersburg, Russia, August 20-22, 2003.

Методы обучения и самоорганизации полиномиальных нейронных сетей в задачах распознавания образов

А.В. Тимофеев
(Санкт-Петербург)

Введение

Эффективным средством распознавания образов и классификации данных являются полиномиальные нейронные сети (ПНС) с самоорганизующейся архитектурой минимальной сложности и их разновидности (диофантовые, многозначные и т.п. ПНС). Математические модели, методы обучения и принципы самоорганизации ПНС были предложены и развиты в [1-7]. К ним относятся: модели полиномиальных, конъюнктивных и дизъюнктивных нейронных элементов (Р-нейроны, К-нейроны, D-нейроны); самоорганизующиеся архитектуры ПНС различных типов; детерминированные и вероятностные методы обучения ПНС; принцип минимальной сложности и высокой экстраполирующей силы ПНС; требование диофантовости (целочисленности синаптических весов) ПНС.

В процессе развития теории ПНС были предложены модели многозначных нейронных элементов (М-нейроны), конструктивные методы обучения и самоорганизации многозначных ПНС и их новые разновидности (генно-нейронные сети, квантовые, мульти-агентные ПНС и т.п.) [8-12].

Самоорганизующиеся порогово-полиномиальные нейронные сети

Опишем формально архитектуру трёхслойной порогово-полиномиальной сети (ППНС). Первый слой НС состоит из n пороговых элементов НЭ, на вход которых поступают сигналы $y_l(\omega)$, характеризующие свойства объекта ω , а на выходе формируются двоичные сигналы вида

$$x_i(\omega) = \text{sgn}\left(\sum_{l=1}^p \gamma_{i,l} y_l(\omega) + \gamma_{i,0}\right), \quad i = 1, \dots, n. \quad (1.1)$$

Эти сигналы подаются на "ассоциативные" НЭ второго, реализующих полиномиальные преобразования $a_j(x)$ (Р-нейроны). Третий слой состоит из "решающих" пороговых НЭ вида

$$\hat{R}_k(\omega) = \text{sign}\left(\sum_{j=1}^N u_{k,j} a_j(x(y(\omega)))\right), \omega \in \Omega = \bigcup_{k=1}^K \Omega_k, \quad (1.2)$$

где u_k - вектор синаптических параметров, K - число классов.

Целью ППНС является аппроксимация (1.1), (1.2) неизвестных распознающих функций (РФ) $R_k(\omega)$ как характеристических функций классов Ω_k по обучающей БД табличного типа

$$\{x_1(\omega_h), \dots, x_n(\omega_h), R_k(\omega_h)\}, h = 1, \dots, m. \quad (1.3)$$

Принцип самоорганизации ППНС [1,2] заключается в построении “ассоциативных” НЭ непосредственно по обучающей БД (1.3) в виде

$$a_j(x(\omega)) = \prod_{i=1}^n x_i(\omega)^{x_i(\omega_j)}, j = 1, \dots, m. \quad (1.4)$$

Чтобы минимизировать сложность ППНС, нужно найти векторы синаптических параметров с максимальным числом нулевых компонент. Это приводит к ликвидации неинформативных синаптических связей без потери точности. Рекуррентные алгоритмы обучения, минимизирующие сложность ППНС, предложены в [2,3,6,7]. Они осуществляют отображение обучающих БД на множество синаптических параметров ППНС. Принятие оптимальных распознающих решений осуществляется за 3 такта вычислений независимо от размерности решаемой задачи $D=n \times m \times K$.

Самоорганизующиеся диофантовые и сплайновые нейронные сети

ПНС с целочисленными синаптическими параметрами называются диофантовыми НС [4-7]. Примерами диофантовых НС с самоорганизующейся архитектурой, могут служить ПНС, предложенные в [2-3]. Другой класс диофантовых НС отличается выбором полиномиальных НЭ (Р-нейронов) второго слоя в виде

$$d(\omega) = \sum_{i=1}^n x_i(\omega) \cdot 2^{n-i}, \quad (2.1)$$

$$a_j(d(\omega_h)) = \prod_{\substack{h=1 \\ j \neq h}}^{m_k} (d(\omega) - (d(\omega_h))(d(\omega_j) - d(\omega_h)))^{-1}. \quad (2.2)$$

Тогда синаптические параметры можно вычислить по простым формулам $u_{k,j} = R_k(\omega_j), j = 1, \dots, m_k$.

Значительный интерес представляют диофантовые НС, основанные на кусочно-полиномиальной (сплайновой) аппроксимации РФ. Идея состоит в синтезе НЭ по БД (1.3) в виде независимых друг от друга полиномов или сплайнов на каждой паре $[d(\omega_i), d(\omega_{i+1})]$ и их коммутации по

определённым правилам во втором слое НС [7].

Синтезированные диофантовые НС имеют трёхслойную архитектуру, описываемую суперпозицией преобразований в каждом слое НЭ. Самоорганизация и минимизация сложности архитектуры обеспечиваются самонастройкой полиномиальных НЭ и быстрыми алгоритмами обучения, требующими однократного использования обучающей БД. Принятие оптимальных решений осуществляется за 3 такта параллельных вычислений независимо от размерности задачи $D = n \times m \times K$.

Самоорганизующиеся многозначные диофантовые нейронные сети

Рассмотрим четырёхслойную ПНС, состоящую из функциональных НЭ (F-нейроны), полиномиальных НЭ (P-нейроны), суммирующих НЭ (Σ -нейроны) и одного многозначного НЭ (M-нейрона), описываемого многозначным предикатом. Такая ПНС реализует преобразование вектора входных сигналов $y(\omega)$ в выходной целочисленный сигнал вида

$$R(\omega) = M(u_0 + \sum_{j=1}^N u_j \prod_{i \in J_j} F_i(y(\omega), \gamma)), \quad R \in \{1, \dots, K\}, \quad (3.1)$$

определяющий номер класса Ω_k . Задача обучения, минимизации сложности и самоорганизации многозначных диофантовых ПНС с аналитическим описанием вида (3.1) заключается в определении функций F_i и a_j и векторов синаптических параметров γ и u по обучающей БД таким образом, чтобы обеспечивалась не только безошибочная классификация объектов из обучающей БД, но и других (контрольных) объектов.

Генно-нейронные и байесовские самоорганизующиеся сети

Методы обучения и самоорганизации генно-нейронных (ГНС) логико-вероятностного типа основаны на генетических алгоритмах байесовской селекции информативных генов и конъюнктивных НЭ (K-нейронов). В этом случае гены характеризуются двоичными или многозначными предикатами, а хромосомы являются их конъюнкциями. Байесовский метод синтеза логико-генетических описаний классов сводится к следующему [1,3,4]:

- 1) селекция наиболее информативных K-нейронов $a^r(\omega)$ по возрастающим рангам $r=1,2,\dots$, по критерию Байеса;
- 2) синтез импликативных логико-вероятностных РФ вида

$$\{a_j^r(\omega) \rightarrow \Omega_k\}_{j=1}^N, \quad 1 \leq r_1 \leq r_2 \leq \dots \leq r_N < n, \quad (4.1)$$

где P_k - максимальная вероятность класса Ω_k , оцененная по обучающей БД.

Синтезированные РФ вида (4.1) в случае многозначных генов можно

представить в виде графа многослойной ГНС минимальной сложности, представляющий собой “многозначное дерево решений”, листьям которого соответствуют номера классов, вершинам - многозначные гены, а ветвям - их целочисленные состояния. Путь на графе представляет собой минимальное логическое описание хромосом, на которых истинна конъюнкция генетических признаков, соответствующая этому пути. Все такие конъюнкции ортогональны, а логико-генетические описания классов статистически независимы. Многослойные ГНС можно преобразовать в трёхслойные диофантовые ПНС с помощью метода, описанного в [11].

Заключение

Описанные конструктивные методы обучения, самоорганизации и минимизации сложности ПНС успешно применялись для решения ряда прикладных задач распознавания образов, медицинской диагностики, классификации данных, идентификации классов, прогнозирования явлений и нейросетевого представления генетического кода [2-12].

Работа выполнена при поддержке грантов РГНФ № 03-06-12019в, РФФИ № 03-01-00224 и Минпромнауки РФ № 37.029.11.0027.

Литература

1. Тимофеев А.В. Об одном классе полиномиальных разделяющих функций в задачах опознавания и диагностики. - Методы вычислений. - Л.: Изд-во ЛГУ, 1971, вып.7, с. 106-121.
2. Пшибихов В.Х., Тимофеев А.В. Алгоритмы обучения и минимизации сложности полиномиальной опознающей системы. - Изд. АН СССР. Техническая кибернетика, 1974, № 5, с. 214-217.
3. Пшибихов В.Х., Тимофеев А.В. Полные системы логических решающих функций и оптимальные опознающие графы. - Методы вычислений. - Л.: Изд-во ЛГУ, 1974, вып. 9, с.44-51.
4. Timofeev A.V. Intelligent Control Applied to Non-Linear Systems and Neural Networks with Adaptive Architecture -Journal of Intelligent Control, Neurocomputing and Fuzzy Logic, 1997, Vol.1, N1, pp. 1-18.
5. Каляев А.В., Тимофеев А.В. Методы обучения и минимизации сложности когнитивных нейромодулей супер- макро- нейрокомпьютера с программируемой архитектурой. - Доклады Академии Наук, 1994, т. 237, с. 180-183.
6. Тимофеев А.В. Нелинейные методы оценки информативности метеорологических параметров и классификации метеорологических явлений. - Метеорология и гидрология. 1975, № 1, с.13-23.
7. Тимофеев А.В. Методы синтеза диофантовых нейросетей минимальной сложности. - Доклады Академии Наук, 1995, т.301, № 3, с.1106-1109.
8. Timofeev A.V. Semyonov A.V. Genetic Algorithms of Database Control and Knowledge Base Synthesis and Their Applications. - International Journal of Information Theories & Application, 1996, v.4, 1, pp. 17-22.

9. Тимофеев А.В., Шибзухов З.М. Методы синтеза и минимизации сложности диофантовых нейронных сетей над конечным полем.- Автоматика и телемеханика, 1997, № 4, с. 204-212.
10. Тимофеев А.В. Оптимальный синтез, и минимизация сложности генно-нейронных сетей по генетическим базам данных. - Нейрокомпьютеры: разработка и применение, № 5-6, 2002, с. 34-39.
11. Тимофеев А.В., Шибзухов З.М., Шеожев А.М. Синтез нейросетевых архитектур по многозначному дереву решений. - Нейрокомпьютеры: разработка и применение, № 5-6, 2002, с. 44-49.
12. Тимофеев А.В. Эволюция нейроинформатики: от перцептронов к квантовым нейрокомпьютерам. - Нейрокомпьютеры: разработка и применение, № 5-6, 2002, с. 107-115.

Интервальный критерий синхронизации – десинхронизации сигналов

О.Е. Трофимов, А.С. Загоруйко

(Новосибирск)

Задача, решаемая в настоящей работе, заключается в объективной количественной оценке степени синхронизации-десинхронизации пар сигналов различной природы: биологической, экономической и др. .

Синхронизация-десинхронизация сигналов понимается в следующем смысле. Два сигнала ведут себя синхронно на временном интервале, если на этом интервале оба сигнала или увеличиваются, или уменьшаются. Сигналы ведут себя десинхронно, если один сигнал увеличивается (уменьшается), то другой уменьшается (увеличивается).

В качестве сигналов биологической природы рассмотрены сигналы ЧСС (частота сердечных сокращений) и РФ (размах фотоплетизмограммы). Сигналы получены в сеансах тренинга методом многоканальной биологической обратной связи (МБОС [1]) одного из авторов настоящей работы. Из сигналов экономической природы - сигналы, характеризующие темпы прироста физического объема валового внутреннего продукта (ВВП) в постсоветских государствах в 1996-2001 годах. Данные взяты из работы [2].

Интервальный метод оценки степени синхронизации-десинхронизации пар сигналов

Предлагаемый интервальный метод оценки степени синхронизации-десинхронизации пар сигналов заключается в анализе величин изменений исследуемых сигналов и знаков их производных на элементарных временных интервалах и суммировании результатов по всем интервалам определенным образом. Элементарный временной интервал – это отрезок времени между двумя последовательными отсчетами сигналов.

Для оценки степени синхронизации-десинхронизации пар сигналов можно использовать и корреляционные критерии для самих сигналов или их производных. Однако, эти критерии хорошо работают лишь в случае линейных (или близких к линейным) зависимостей между исследуемыми сигналами.

По интервальному методу составляющие показателя оценки синхронизации-десинхронизации сигналов $P(t)$ и $R(t)$ определяются следующим образом:

$$K_{snxr}^{s+} = \frac{\sum_{j=1}^{k+} (dP_j + dR_j)}{\sum_{j=1}^{k+} (dP_j + dR_j) + \sum_{i=1}^{k-} (dP_i + dR_i)}, \quad K_{snxr}^{t+} = \frac{k+}{M} * 100\%,$$

$$K_{snxr}^{+} = K_{snxr}^{s+} * K_{snxr}^{t+},$$

$$K_{snxr}^{s-} = \frac{-\sum_{i=1}^{k-} (dP_i + dR_i)}{\sum_{j=1}^{k+} (dP_j + dR_j) + \sum_{i=1}^{k-} (dP_i + dR_i)}, \quad K_{snxr}^{t-} = \frac{k-}{M} * 100\%,$$

$$K_{snxr}^{-} = -K_{snxr}^{s-} * K_{snxr}^{t-},$$

где: $dP_i=|P_i-P_{i-1}|$ - абсолютное значение изменения сигнала $P(t)$ на элементарном интервале (получаемая при $i=1$ величина P_0 - начальное значение сигнала); $dR_i=|R_i-R_{i-1}|$ - абсолютное значение изменения сигнала $R(t)$ на элементарном интервале; M - общее количество элементарных интервалов; $k+$ - количество элементарных интервалов, на которых сигналы ведут себя синхронно (оба сигнала или увеличиваются, или уменьшаются); $(k-)$ - количество элементарных интервалов, на которых сигналы ведут себя десинхронно (если один сигнал увеличивается (уменьшается), то другой уменьшается (увеличивается)); $K_{snxr}^{s+}, K_{snxr}^{s-}$ - положительная и отрицательная составляющие показателя синхронизации-десинхронизации сигналов по критерию суммарной величины их синхронного-десинхронного изменения ($K_{snxr}^{s+} + K_{snxr}^{s-} = 1$); $K_{snxr}^{t+}, K_{snxr}^{t-}$ - положительная и отрицательная составляющие показателя синхронизации-десинхронизации сигналов по критерию суммарной величины времени их синхронного-десинхронного изменения ($K_{snxr}^{t+} + K_{snxr}^{t-} = 100\%$); $K_{snxr}^{+}, K_{snxr}^{-}$ - положительная и отрицательная составляющие показателя синхронизации-десинхронизации

сигналов.

Суммированием величин K_{snxr}^+ и K_{snxr}^- определяется результирующий интервальный показатель синхронизации-десинхронизации сигналов: K_{snxr} .

Сигналы сеансов МБОС-тренинга.

На рисунке 1 представлена зависимость коэффициентов синхронизации-десинхронизации K_{snxr} ЧСС-РФ-сигналов 24-го сеанса тренинга от сдвига РФ(RF)-сигнала относительно ЧСС(PLS)-сигнала на $S=Sx-1$ интервалах (Sx – значение оси абсцисс). Наблюдается периодичность появления максимума синхронизации с убывающей с увеличением сдвига амплитудой.

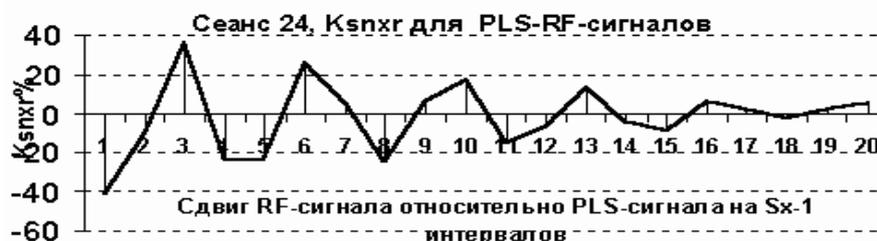


Рис. 1.

Сигналы экономической природы.

Была вычислена квадратная симметричная матрица попарной синхронизации-десинхронизации сигналов, характеризующих темпы прироста физического объема ВВП в 14-ти постсоветских государствах в 1996-2001 годах.: Азербайджан (Az-1), Армения (Ar-2), Беларусь (Bl-3), Грузия (Gr-4), Казахстан (Ka-5), Кыргызстан (Ki-6), Молдова (Mo-7), Россия (Rs-8), Таджикистан (Ta-9), Узбекистан (Uz-10), Украина (Uk-11), Латвия (La-12), Литва (Li-13), Эстония (Es-14).

На рисунке 2 изображена диаграмма коэффициентов синхронизации-десинхронизации K_{snxr} данных, характеризующих темпы прироста ВВП России, с данными всех рассматриваемых государств.



Рис. 2.

Анализ упомянутой выше матрицы позволил выделить две группы государств со 100%-ой попарной синхронизацией. Одна группа - это Латвия,

Эстония и Беларусь. Другая группа - Молдова и Казахстан.

Работа поддержана грантами РФФИ N 03-01-00910 и N 03-07-90060.

Литература

1. Zakharova V., Trofimov O., Zagoruyko A., Zhuravel F. MBFB–Training Phase Identification on Interval Criteria of Efficiency And Synchronizing // Proceeding of the IASTED International Conference Automation, Control, and Information Technology. Novosibirsk, Russia, June 10-13, 2002. PP. 111-114.
2. Гайдар Е. Перспективы экономического развития России // Финансовые Известия. (<http://www.finiz.ru/business/article.8779>). Февраль, 25, 2003.

Об одном методе получения оценок

Б.З. Угольникова, С.А. Жданов

(Москва)

Рассматривается алгоритм получения оценок знаний респондента, базирующийся на применении конечного автомата с заранее указанными функциями переходов и выходов.

Пусть задача состоит в оценке ответа данного респондента по 5-бальной системе. Рассмотрим следующие множества: входной алфавит $A = \{1, 2, \dots, 10\}$, т.е. те оценки, которые респондент получает в n -ый момент времени (после ответа на n -ый вопрос), где

1 — соответствует оценке 2;

2 — 2+;

3 — 3 -;

4 — 3;

5 — 3+;

6 — 4 -;

7 — 4;

8 — 4+;

9 — 5 -;

10 — 5,

и выходной алфавит $B = \{2, 3, 4, 5\}$.

Множество состояний автомата: $Q = \{q_0, q_1, \dots, q_7\}$, где нахождение

автомата в состоянии q_1 соответствует оценке 2,

в состоянии q_2 между 2 и 3,

в состоянии q_3 — 3,

в состоянии q_4 между 3 и 4,

в состоянии q_5 — 4,

в состоянии q_6 между 4 и 5,

в состоянии q_7 — 5.

Автомат в начальный момент времени находится в том состоянии q_i $i = 1, \dots, 7$, которое соответствует предварительной оценке респондента. Если об испытуемом нет никаких предварительных сведений, то автомат находится в начальном состоянии q_0 .

Определим функции выходов данного автомата следующим образом:

$$\phi(q_0, a_i) = 1.5$$

$$\phi(q_1, a_i) = 2,$$

$$\phi(q_2, a_i) = 2.5,$$

$$\phi(q_3, a_i) = 3,$$

$$\phi(q_4, a_i) = 3.5,$$

$$\phi(q_5, a_i) = 4,$$

$$\phi(q_6, a_i) = 4.5,$$

$$\phi(q_7, a_i) = 5,$$

где $a_i \in A$.

В данный момент времени выход автомата полностью определяется состоянием, в котором автомат находится. Таким образом, если автомат находится в одном из состояний q_1, q_3, q_5, q_7 , то респондент получает соответствующую оценку. Если же автомат находится в одном из "спорных" состояний q_2, q_4 или q_6 , то надо использовать другие методы. Например, применить на данном шаге автомат без "спорных" состояний.

Для "разумной" оценки предлагаются следующие функции переходов:

$$\varphi(q_0, 1) = q_1, \quad \varphi(q_0, 2) = \varphi(q_0, 3) = q_2,$$

$$\varphi(q_0, 4) = q_3, \quad \varphi(q_0, 5) = \varphi(q_0, 6) = q_4,$$

$$\varphi(q_0, 7) = q_5, \quad \varphi(q_0, 8) = \varphi(q_0, 9) = q_6, \quad \varphi(q_0, 10) = q_7;$$

$$\varphi(q_1, 1) = \varphi(q_1, 2) = q_1, \quad \varphi(q_1, 3) = \varphi(q_1, 4) = q_2,$$

$$\varphi(q_1, 5) = \varphi(q_1, 6) = \varphi(q_1, 7) = q_3,$$

$$\varphi(q_1, 8) = \varphi(q_1, 9) = \varphi(q_1, 10) = q_4;$$

$$\varphi(q_2, 1) = \varphi(q_2, 2) = q_1,$$

$$\varphi(q_2, 3) = \varphi(q_2, 4) = \varphi(q_2, 5) = \varphi(q_2, 6) = q_3,$$

$$\varphi(q_2,7) = \varphi(q_2,8) = \varphi(q_2,9) = q_4, \varphi(q_2,10) = q_5;$$

$$\varphi(q_3,1) = \varphi(q_3,2) = q_2, \varphi(q_3,3) = \varphi(q_3,4) = \varphi(q_3,5) = q_3, \\ \varphi(q_3,6) = \varphi(q_3,7) = \varphi(q_3,8) = q_4, \varphi(q_3,9) = \varphi(q_3,10) = q_5;$$

$$\varphi(q_4,1) = \varphi(q_4,2) = q_2, \varphi(q_4,3) = \varphi(q_4,4) = q_3, \\ \varphi(q_4,5) = q_4, \varphi(q_4,6) = \varphi(q_4,7) = \varphi(q_4,8) = \varphi(q_4,9) = q_5, \\ \varphi(q_4,10) = q_6;$$

$$\varphi(q_5,1) = \varphi(q_5,2) = q_3, \varphi(q_5,3) = \varphi(q_5,4) = \varphi(q_5,5) = q_4, \\ \varphi(q_5,6) = \varphi(q_5,7) = \varphi(q_5,8) = q_5, \varphi(q_5,9) = \varphi(q_5,10) = q_6;$$

$$\varphi(q_6,1) = \varphi(q_6,2) = q_3, \varphi(q_6,3) = \varphi(q_6,4) = q_4, \\ \varphi(q_6,5) = \varphi(q_6,6) = \varphi(q_6,7) = q_5, \varphi(q_6,8) = q_6, \\ \varphi(q_6,9) = \varphi(q_6,10) = q_7;$$

$$\varphi(q_7,1) = \varphi(q_7,2) = q_4, \\ \varphi(q_7,3) = \varphi(q_7,4) = \varphi(q_7,5) = \varphi(q_7,6) = q_5, \\ \varphi(q_7,7) = \varphi(q_7,8) = q_6, \varphi(q_7,9) = \varphi(q_7,10) = q_7.$$

Отметим, что функции переходов и выходов одни и те же для каждого респондента. Меняются только начальные состояния.

О стохастической модели меры возможности

О.В. Фаломкина

(Москва)

В монографии [1] рассмотрены два различных варианта теории возможностей, в которых возможность принимает значения в шкале $L = \{[0,1], \leq, +, \bullet\}$ ¹, причем в первом варианте сложение «+» определено как «max», умножение «•» определено как «min», а во втором варианте

¹ Шкала L – это отрезок $[0,1]$ числовой прямой с естественной упорядоченностью, определенной неравенством \leq и двумя правилами композиции: сложением $+: [0,1] \rightarrow [0,1]$ и умножением $\bullet: [0,1] \rightarrow [0,1]$.

сложение «+» определено как «max», а умножение «•» определено как «•» (обычное умножение). Первая шкала значений возможности инвариантна относительно группы Γ непрерывных изотонных преобразований отрезка $[0,1]$ в себя, оставляющих неподвижными точки 0 и 1, поэтому в этой шкале могут быть содержательно истолкованы лишь отношения «больше», «меньше» или «равно». Вторая шкала значений возможности инвариантна относительно группы преобразований $\tilde{\Gamma} = \{\tilde{\gamma}(\cdot) : [0,1] \rightarrow [0,1], \tilde{\gamma}(x) = x^\alpha, \alpha > 0\}$, поэтому в ней могут быть содержательно истолкованы значения инварианта

$$I_{ab} = \frac{\ln a}{\ln b}, \quad a, b \in [0,1].$$

Первый вариант теории возможностей

рассмотрен в монографии подробно, тогда как для второго варианта приведены лишь основы теории, рассмотрен закон больших чисел и т. п.

В докладе пойдет речь о втором варианте теории возможностей, в частности – о стохастической модели меры возможности, которая позволит эмпирически восстанавливать теоретико-возможностные модели аналогично тому, как это сделано в [2, 7]. Как известно, проблема эмпирического восстановления распределения возможностей является в теории возможностей одной из основных. В докладе предложено решение этой проблемы для второго варианта теории возможностей, показано, что операции сложения «+» в теории вероятностей соответствует операция «max» сложения в теории возможностей, операции умножения «•» в теории вероятностей – операция «•» умножения в теории возможностей, теоретико-вероятностной независимости – теоретико-возможностная независимость, продемонстрирована согласованность условной возможности и условной вероятности и т. д. В докладе также рассматривается постановка и решение задачи оценивания, восстановления функциональной зависимости [6] в рамках второго варианта теории возможностей и проиллюстрирована роль правила Демпстера [4] оптимального вывода в задачах принятия решений, которое во втором варианте теории возможностей получено на основании соображений, не имеющих ничего общего с приведенными в [4, 5].

Интересно отметить, что второй вариант теории возможностей может найти применение в биологии, в частности, при исследовании процессов преобразования информации живыми организмами. Как известно, если F – интенсивность стимула, поступающего на вход органа восприятия живого организма, ΔF – едва заметное изменение интенсивности стимула, то

$$\frac{\Delta F}{F} = \Delta(\ln F) = \text{const}$$

(вариант закона Вебера - Фехнера, см. [3]). Во втором варианте теории возможностей переход от шкалы L к эквивалентной шкале L' значений

возможности совершается путем преобразования $a \rightarrow a' = a^\alpha$, $a \in L$, $\alpha > 0$. Следовательно, закон Вебера-Фехнера, верный для шкалы L , верен и для любой эквивалентной ей шкалы L' при другом значении константы $const$ (другой чувствительности).

Автор благодарит профессора Пытьева Ю.П. за предоставленную интересную тему, а также за полезные и плодотворные обсуждения.

Литература

1. Пытьев Ю.П. Возможность. Элементы теории и применения. Изд-во Эдиториал УРСС, Москва 2000.
2. Pyt'ev Yu.P. About limiting Theorems in Possibility Theory.// Pattern Recognition and Image Analysis (в печати).
3. Дж. Стюарт. Модель слуха. // Проблемы бионики. Биологические прототипы и синтетические системы. М.: Мир, 1965.
4. Dempster A. P. Upper and lower probabilities induced by a multivalued mapping //Annals of Mathematical Statistics, Series B, 30, pp. 205--247.
5. A mathematical theory of evidence. Princeton University Press, Princeton N.J.
6. Жучко О.В., Пытьев Ю.П. Теоретико-возможностные методы восстановления функциональных зависимостей по данным измерений с ошибками. //Доклады X Всероссийской конференции <<Математические методы распознавания образов>>, Москва 2001.
7. Пытьев Ю.П. Стохастические модели возможности. //Доклады X Всероссийской конференции <<Математические методы распознавания образов>>, Москва 2001.

О вычислительной сложности задачи о минимальном комитете

М.Ю. Хачай

(Екатеринбург)

Комитетные алгоритмы обучения распознаванию образов (см., обзор в [1]) предназначены для построения коллективных решающих правил с элементами из заданного базового класса и использованием логики голосования большинством голосов. По ряду объективных причин наибольший интерес представляют алгоритмы, позволяющие для каждой частной задачи обучения, определяемой обучающей выборкой и классом базовых правил, находить правило с наименьшим или близким к наименьшему числом элементов (так называемые *минимальные разделяющие комитеты*). Известно, что задача построения комитетного правила эквивалентна задаче поиска комитетного обобщенного решения (*комитета*) подходящей системы ограничений, записываемой как правило в

виде системы алгебраических уравнений или неравенств. Ниже обсуждается вопрос оценки вычислительной сложности этой задачи, в частности, описан новый приближенный алгоритм ее решения в случае, когда система ограничений является системой линейных неравенств.

Пусть X - произвольное непустое множество и задан набор его подмножеств D_1, D_2, \dots, D_m . Рассмотрим не обязательно совместную систему включений

$$x \in D_j \quad (j \in \square_m = \{1, 2, \dots, m\}). \quad (1)$$

Как обычно (см., например, [1]), комитетом большинства системы (1) из q элементов (или просто комитетом) назовем такую конечную последовательность $Q = (x^1, x^2, \dots, x^q)$ элементов множества X , что

$$\left| \left\{ i \in \square_q : x^i \in D_j \right\} \right| > \frac{q}{2} \quad (j \in \square_m).$$

Задачей о минимальном комитете (МК) называется следующая задача:

Дано: непустое множество X и семейство его подмножеств D_1, D_2, \dots, D_m .

Требуется найти: комитет системы (1) с минимальным возможным числом элементов.

Задача МК является комбинаторной и в общем случае труднорешаема. Известна, например (см. [1]),

Теорема 1. Пусть X, D_1, D_2, \dots, D_m - конечные множества. Задача о минимальном комитете NP-трудна.

С задачей МК тесно связана следующая задача целочисленного линейного программирования. Обозначим, как обычно, через J_1, J_2, \dots, J_Q индексные множества (индексы) максимальных по включению совместных подсистем (м.с.п.) системы (1) и рассмотрим задачу

$$\min \left\{ \sum_{i=1}^Q t_i : Ct \geq e, t \in \square_{\frac{Q}{+}} \right\}, \quad (2)$$

в которой $C - \{1, -1\} \ m \times Q$ матрица инцидентий включений и индексов м.с.п, а вектор $e = [1, 1, \dots, 1]^T \in E_m$. Справедливы следующие результаты:

Теорема 2. Задачи МК и (2) разрешимы или неразрешимы одновременно. Множество решений (2) изоморфно вкладывается в множество решений задачи МК.

Теорема 3. Пусть множества D_1, D_2, \dots, D_m – конечны. Тогда задачи МК и (2) полиномиально эквивалентны.

Следствие. Задача (2) в общем случае NP -трудна.

Теорема 4. Пусть оптимальное значение задачи (2) оценивается сверху полиномом от m и Q . Тогда задача (2) может быть решена за время, полиномиальное относительно этих же параметров.

Таким образом, не смотря на то, что в общем случае переход от решения задачи МК к решению задачи (2), по-видимому, не рационален, в частных случаях он может оказаться продуктивным. Особый интерес представляет случай задачи о минимальном комитете несовместной системы линейных неравенств (МКЛН):

$$(a_j, x) > 0 \quad (j \in \square_m). \quad (3)$$

Здесь $X = \{x \in \square^n : \|x\|_2 \leq 1\}$, $n > 1$ и $D_j = \{x \in X : (a_j, x) > 0\}$.

Теорема 5. Задача МКЛН в классе систем с ограничением на размерность пространства полиномиально разрешима.

Доказательство теоремы получается сведением задачи МКЛН к подходящей задаче (2), параметр Q которой ограничен сверху полиномом от m . Следует отметить, что, вероятно возможно построение и прямого эффективного алгоритма решения исходной задачи.

В частности, в работе [2] описан полиномиальный приближенный (в смысле [3]) алгоритм решения задачи при дополнительных условиях на систему (3):

- 1) $m > n$ и каждая подсистема из n неравенств совместна;
- 2) $m = 2k + n - 1$ для некоторого натурального k .

Теорема 6.

1. Алгоритм корректен и находит решение задачи не более чем за $\left\lceil \frac{m}{n-1} \right\rceil$ «больших» итераций.
2. Пусть мощности м.с.п. системы (3) равномерно ограничены сверху числом $k + t + n - 1$ (для $t \in \square_+$), тогда справедливы неравенства

$$1 \leq \frac{q_{\text{approx}}}{q_{\text{min}}} \leq \frac{2^{\left\lceil \frac{k}{n-1} \right\rceil + 1}}{2^{\left\lceil \frac{k-t}{2t+n-1} \right\rceil + 1}} \approx 1 + \frac{2t}{n-1}.$$

Для произвольного $n > 1$ существует бесконечный класс систем

линейных неравенств над \square^n в котором упомянутый алгоритм является точным (а задача МКЛН, соответственно, полиномиально разрешима). Этот класс включает в себя класс *равномерно распределенных по Гейлу* систем неравенств. Система из $m = 2k + n - 1$ в n -мерном пространстве равномерно распределена, если для каждого $0 \neq x \in \square^n$ справедливо условие:

$$\left| \left\{ j : (a_j, x) > 0 \right\} \right| \geq k.$$

Теорема 7. Минимальный комитет равномерно распределенной по Гейлу системы неравенств (3) состоит из $2 \left\lceil \frac{k}{n-1} \right\rceil + 1$ элементов и может быть найден упомянутым выше алгоритмом за полиномиальное время.

Работа выполнена при поддержке РФФИ, гранты №№ 01-01-00563 и НШ-792.2003.1.

Литература

1. Mazurov V.I.D., Khachai M.Yu., Rybin A.I. Committee constructions // Proceedings of the Steklov institute of mathematics. 2002, suppl. 1, p.67–101.
2. Khachai M.Yu. On an Efficient Approximation Algorithm for Minimal Committee Machine Learning // PRIA. 2003. vol. 13, no. 1, p. 43–44.
3. Williamson D.P. The Primal-Dual Method for Approximation Algorithms // Mathematical Programming. 2002. vol. 91, no. 3. ser. B, p. 447–478.

Образный анализ и диагностика сложных процессов

В.М. Хачумов, Е.В. Ксенофонтова

(Переславль-Залесский)

Введение

В настоящее время возрос интерес к методам обработки информации, использующим уникальные возможности человека воспринимать и анализировать абстрактные графические изображения. Эти возможности в полной мере использует образный анализ данных, в основе которого лежит принцип эффективного разделения функций между человеком и ЭВМ [1,2,3]. В рамках данного направления в настоящей работе рассматривается задача контроля и диагностики сложного технического изделия. ЭВМ производит преобразование контролируемых данных в когнитивные (контурные, цветояркие и др.) представления, которые помогают человеку-оператору установить класс неисправности и принять решение.

Диагностика на основе образного анализа

Для диагностики предлагается использовать иерархическую систему представления информации о контролируемом объекте: уровень, отображающий состояние системы в целом; уровень подсистемы и уровень параметров. В качестве объекта экспериментального исследования была выбрана подсистема поддержания избыточного давления в баке (рис.1.).

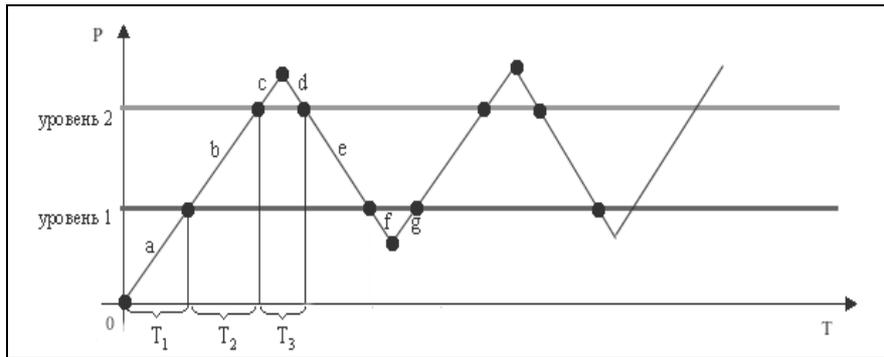


Рис.1. Схема процесса поддержания избыточного давления в баке

Построению образов подсистемы предшествует логическое описание ситуации. Признаки принимают значения: “1” или “0”, что соответствует значениям “да”, “нет”. Классы неисправностей описываются в виде дизъюнктивно-нормальных форм (ДНФ). Зададим набор характерных признаков ($x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8, x_9$), определяющих соответственно

ситуации: клапан открыт; процесс на участке T_1 ; срабатывание счетчика реле низкого давления; срабатывание счетчика реле высокого давления; число срабатываний реле низкого и высокого давления отличается на единицу; число срабатываний реле низкого давления превышает число срабатываний реле высокого давления; процесс на участке T_2 ; процесс на участке T_3 ; число срабатываний реле высокого давления превышает число срабатываний реле низкого давления. Определим типы отказов: w_1, w_2, w_3, w_4 - соответственно отказ: клапана; отказ реле низкого давления; отказ реле высокого давления; утечка. Опишем классы отказов:

$$w_1 = \bar{x}_1 x_2 \vee \bar{x}_1 x_3 x_5 x_6 x_7 \vee x_1 x_4 \bar{x}_5 \bar{x}_6 \vee x_1 x_4 x_5 x_7 x_9 \vee \bar{x}_1 x_3 \bar{x}_5 \bar{x}_8,$$

$$w_2 = x_1 \bar{x}_2 \bar{x}_3 \vee x_1 \bar{x}_3 x_4 x_7 \vee \bar{x}_1 \bar{x}_3 x_5 \bar{x}_7 x_9 \vee x_1 \bar{x}_3 \bar{x}_5 \bar{x}_8,$$

$$w_3 = x_1 x_3 \bar{x}_4 \bar{x}_7 \vee \bar{x}_1 \bar{x}_4 \bar{x}_5 \bar{x}_8 \vee \bar{x}_1 x_3 x_5 x_6,$$

$$w_4 = x_1 \bar{x}_2 \vee x_1 x_3 x_5 x_6 \bar{x}_7 \vee x_1 \bar{x}_3 \bar{x}_5 \bar{x}_8.$$

Исходными данными для образного представления процесса являются двоичные вектора отказов, для которых предлагается использовать полярную развертку (рис.2).

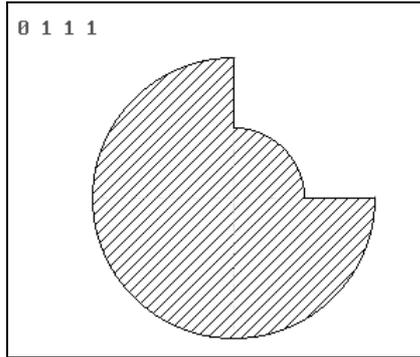


Рис.2. Полярная развертка вектора

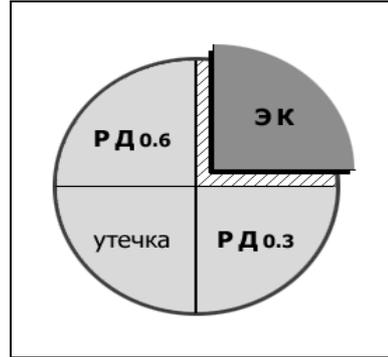


Рис.3. Сегментное представление вектора

Компонента вектора соответствующая классу отказа отображается меньшим радиусом. На рис.3. представлено изображение того же вектора, но добавлен цвет с указанием классов отказа. Класс отказа отображается смещенным сектором. При большой размерности вектора применяют

интегральные контурные представления вида:
$$p(\varphi) = \sum_{k=1}^N x_k \sin(k\varphi).$$

Используются значения N параметров. Контур, описывающий штатную ситуацию, должен лежать между ограничивающими контурами (рис.4).

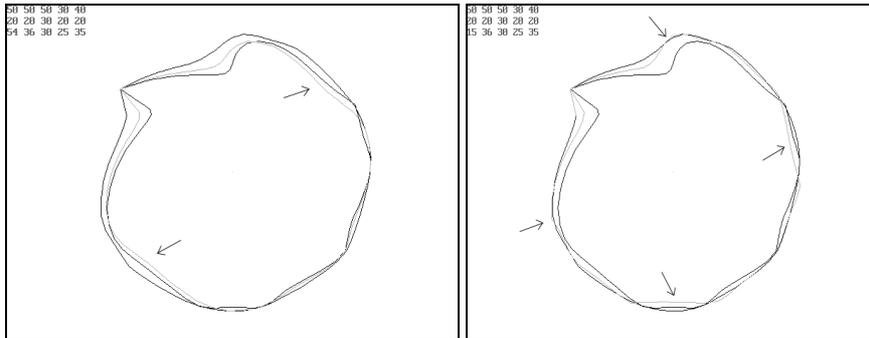


Рис.4. Отображение отклонения первой компоненты вектора

Более наглядным представляется комбинированный образ подсистемы (рис.5). Текущее состояние отображается жирной (красной) линией, которая, в случае штатной ситуации лежит в пределах ограничивающих колец. На

рис.5 показан обобщенный динамический образ системы в целом.

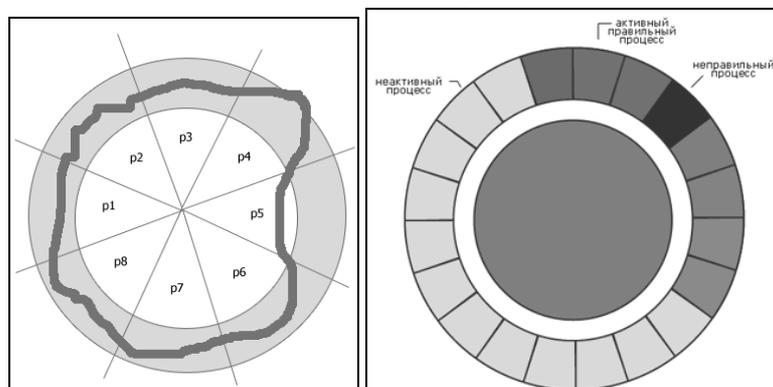


Рис.5. Цветояркие образы подсистемы и системы

Каждый сектор соответствует отдельному процессу (подсистеме). Неактивные процессы отображаются приглушенным (зеленым) цветом, а активные – ярким. Нештатный процесс отображается ярко-красным цветом.

Литература

1. Гришин В.Г. Образный анализ экспериментальных данных - М.: Наука. 1982. - 238 с.
2. Поспелов Г.С. Искусственный интеллект – основа новой информационной технологии. – М.: Наука, 1988. -280 с.
3. Зенкин А.А. Когнитивная компьютерная графика. – М.: Наука, 1991. - 192 с.

О свойстве простой подстановки для неклассических логик

В.И. Хомич

(Москва)

Настоящее сообщение посвящено изучению введенного в работах [1,2] свойства простой подстановки, касающегося суперинтуиционистских пропозициональных логик (т.е. расширений интуиционистской пропозициональной логики [3]) и модальных пропозициональных логик (т.е. нормальных расширений модальной пропозициональной логики $S4$ [4]). Это свойство изучалось в работах [1-2,5-8].

Пусть H – интуиционистское пропозициональное исчисление [3], а $S4$ – модальное пропозициональное исчисление [4]. Суперинтуиционистское пропозициональное исчисление (нормальное модальное пропозициональное расширение исчисления $S4$), получающееся из H ($S4$) путем добавления в список его аксиом конечного множества пропозициональных (модальных пропозициональных) формул K , называемых его дополнительными

аксиомами, будем обозначать через $H+K$ ($S4 \oplus K$). Суперинтуиционистской пропозициональной логикой (модальной пропозициональной логикой) называется множество пропозициональных (модальных пропозициональных) формул, содержащее все аксиомы H ($S4$) и замкнутое относительно правила подстановки и правила модус поненс (правила подстановки, правила модус поненс и правила обобщения с помощью модальной связки необходимости). Исчисление $H+K$ ($S4 \oplus K$) называется аксиоматизацией суперинтуиционистской (модальной) пропозициональной логики, если в нем выводимы все ее формулы и только они.

Пусть Y – пропозициональная или модальная пропозициональная формула, построенная из переменных b_1, \dots, b_n , а d_1, \dots, d_m – различные пропозициональные переменные. Конъюнкцию всех формул, полученных в результате всевозможных подстановок в Y вместо переменных b_1, \dots, b_n переменных d_1, \dots, d_m будем обозначать через $Y[d_1, \dots, d_m]$. Будем говорить, что исчисление $H+K$ ($S4 \oplus K$), где $K \neq \emptyset$, обладает свойством простой подстановки [1,2], если какова бы ни была формула Z , построенная из переменных d_1, \dots, d_m и выводимая в $H+K$ ($S4 \oplus K$), в H ($S4$) выводима формула $(\bigwedge_{X \in K} X[d_1, \dots, d_m]) \supset Z$. Естественным образом это

свойство распространяется [1,2] на суперинтуиционистские и модальные пропозициональные логики: а именно, логика обладает свойством простой подстановки, если им обладает некоторая ее аксиоматизация. Заметим, что для изучения свойства простой подстановки этих логик достаточно рассматривать исчисления только с одной дополнительной аксиомой.

Пропозициональная (модальная пропозициональная) формула Y называется общезначимой во множестве Ξ псевдобулевой (топологической булевой) алгебры Θ , если значение каждого выражения, получающегося из Y путем замены переменных формулы Y элементами множества Ξ , а логических знаков соответствующими им операциями алгебры Θ , равно ее выделенному элементу. Если $\Xi = \Theta$, то мы будем говорить просто, что формула Y общезначима в алгебре Θ [9]. Если Y не является общезначимой в алгебре Θ , то Y называется опровержимой в Θ [9]. Пропозициональная (модальная пропозициональная) формула Y называется наследственно общезначимой в псевдобулевой (топологической булевой) алгебре Θ [7], если для любого множества ее образующих Ψ верно, что из общезначимости Y в подмножестве Ψ алгебры Θ следует

общезначимость Y в Θ . Псевдобулева алгебра называется геделевой или вполне связной, если множество всех ее элементов, отличных от выделенного, имеет наибольший элемент. Топологическая булева алгебра называется вполне связной, если множество всех ее открытых элементов, отличных от выделенного, имеет наибольший элемент.

Получены [7,8] следующие результаты, касающиеся свойства простой подстановки для суперинтуиционистских пропозициональных исчислений и логик.

Теорема 1. Какова бы ни была пропозициональная формула Y , исчисление $H+\{Y\}$ обладает свойством простой подстановки тогда и только тогда, когда формула Y наследственно общезначима в каждой конечной геделевой псевдобулевой алгебре.

Множество пропозициональных формул, выводимых в исчислении $H+\{Y\}$, где Y - пропозициональная формула, является суперинтуиционистской пропозициональной логикой, которую будем называть логикой, порожденной формулой Y , и обозначать через $L(Y)$. С помощью теоремы 1 получается следующая теорема, касающаяся логики, рассматриваемой в работе [10].

Теорема 2. Логика $L((\neg b \supset (c \vee d)) \supset ((\neg b \supset c) \vee (\neg b \supset d)))$ не обладает свойством простой подстановки.

Рассмотрим пропозициональные формулы P_0, P_1, \dots от одной переменной b , определенные в работе [11] следующими условиями: $P_0 = b \ \& \ \neg b$, $P_1 = b$, $P_2 = \neg b$, $P_{2i+3} = P_{2i+1} \vee P_{2i+2}$, $P_{2i+4} = P_{2i+3} \supset P_{2i+1}$. На множестве этих формул можно задать операции относительного псевдодополнения, пересечения, объединения и псевдодополнения и, тем самым, превратить его в псевдобулеву алгебру [11], которую обозначим буквой Ω .

С помощью теоремы 1 получается следующая теорема.

Теорема 3. Если пропозициональная формула Y принадлежит логике $L(\neg\neg b \vee (\neg\neg b \supset b))$ и опровержима в псевдобулевой алгебре Ω , то логика $L(Y)$ не обладает свойством простой подстановки.

Теорема 3 позволяет выяснить, какие из логик, порожденных пропозициональными формулами от одной переменной b , обладают свойством простой подстановки. Так как каждая такая формула эквивалентна в H некоторой формуле из множества $\{b \supset b, P_0, P_1, \dots\}$ [11], то для нашей цели достаточно рассмотреть только логики $L(P_0), L(P_1), \dots$. Нетрудно проверить, что $L(P_0) = L(P_1) = L(P_2) = L(P_4)$,

$L(P_3) = L(P_6)$ и $L(P_5) = L(P_8)$. Известно [1], что логики $L(P_0)$, $L(P_3)$ и $L(P_5)$ обладают этим свойством. Согласно результатам работы [11] формула P_i , где $i=7$ или $i \geq 9$, принадлежит логике $L(\neg\neg b \vee (\neg\neg b \supset b))$ и опровержима в псевдобулевой алгебре Ω . Поэтому из теоремы 3 вытекает такое следствие.

Следствие. Логика $L(P_i)$, где $i=7$ или $i \geq 9$, не обладает свойством простой подстановки.

Получены также результаты, касающиеся свойства простой подстановки для модальных пропозициональных логик. Выражение $T(X)$ означает результат отображения пропозициональной формулы X во множество модальных пропозициональных формул (т.е. результат перевода Маккинси-Тарского) [12], а Δ - модальный логический знак необходимости.

Теорема 4. Какова бы ни была модальная пропозициональная формула Z , исчисление $S4 \oplus \Delta Z$ обладает свойством простой подстановки тогда и только тогда, когда формула ΔZ наследственно общезначима в каждой конечной вполне связной топологической булевой алгебре.

Теорема 5. Какова бы ни была пропозициональная формула Y , если исчисление $N+Y$ не обладает свойством простой подстановки, то и исчисление $S4 \oplus T(Y)$ не обладает свойством простой подстановки.

Работа выполнена при финансовой поддержке РФФИ, проект 01-01-00154.

Список литературы

1. Sasaki K. The simple substitution property of the intermediate propositional logics // Bulletin of the Section of Logic, Polish Acad. Sci., Inst. Phil. and Sociol. 1989. V. 18. № 3. P. 94-99.
2. Sasaki K., Shundo S., Hosoi T. The simple substitution property for the normal modal logics // SUT J. Math. 1994. V. 30. № 2. P. 107-128.
3. Клини С. К. Введение в метаматематику. М.: ИЛ, 1957.
4. Фейс Р. Модальная логика. М.: Наука, 1974.
5. Hosoi T., Sasaki K. Finite logics and simple substitution property // Bulletin of the Section of Logic, Polish Acad. Sci., Inst. Phil. and Sociol. 1990. V. 19. № 3. P. 74-78.
6. Sasaki K. The simple substitution property of the intermediate propositional logics of finite slices // Studia Logica. 1993. V. 52. № 1. P. 41-62.
7. Хомич В. И. О свойстве простой подстановки для суперинтуиционистских пропозициональных логик // Доклады РАН. 2000. Т. 374. № 3. С. 318-320.
8. Хомич В. И. О свойстве простой подстановки для суперинтуиционистских пропозициональных логик и о его связи с их

- свойством отделимости // Известия РАН. Серия математическая. 2003. Т. 67. № 2. С. 181-210.
9. Расева Е., Сикорский Р. Математика метаматематики. М.: Наука, 1972.
 10. Kreisel G., Putnam H. Eine Unableitbarkeitsbeweismethode für den intuitionistischen Aussagenkalkül // Arch. f. Math. Logik Grundlagenforschung. 1957. V. 3. P. 74-78.
 11. Nishimura I. On formulas of one variable in intuitionistic propositional calculus // J. Symbolic Logic. 1960. V. 25. № 4. P. 327-331.
 12. McKinsey J. C. C., Tarski A. Some theorems about the sentential calculi of Lewis and Heyting // J. Symbolic Logic. 1948. V. 13. № 1. P. 1-13.

Обобщение метода Монте-Карло для вычисления определенных интегралов

Хоссейн Беврани
(Москва)

Введение

Решение математических задач при помощи метода Монте-Карло довольно популярен. Датой рождения метода Монте-Карло принято считать 1940 год, когда появились статья под названием «The Monte Carlo method». В Советском Союзе первые статьи о нём были опубликованы в 1955-1946 годах.

В этом докладе представлен алгоритм вычисления определенных интегралов при помощи обобщения метода Монте-Карло. Для этого начинаем работу с краткого метода Монте-Карло:

Метод Монте-Карло

Рассмотрим функцию $g(x)$, заданную на интервале (a, b) . Требуемся приближенно вычислить интеграл

$$I = \int_a^b g(x) dx_x \quad (1)$$

Выберем произвольную плотность распределения $f_\xi(x)$ определенную на интервале (a, b) . Наряду со случайной величиной ξ , определенной в интервале (a, b) с плотностью $f_\xi(x)$. Нам понадобится случайная величина

$$U = \frac{g(\xi)}{f_\xi(\xi)} \quad (2)$$

и тогда

$$M U = \int_a^b [g(x) / f_{\xi}(x)] f_{\xi}(x) dx = I. \quad (3)$$

Рассмотрим теперь n независимых случайных одинаковых величин u_1, u_2, \dots, u_n и применим к их сумме центральную предельную теорему; в этом случае запишется так

$$P \left\{ \left| \frac{1}{n} \sum_{i=1}^n U_i - I \right| < 3 \sqrt{\frac{DU}{n}} \right\} \approx 0.997 \quad (4)$$

Это соотношение означает, что если мы выберем n значений $\xi_1, \xi_2, \dots, \xi_n$,

то при достаточно большом n :
$$\frac{1}{n} \sum_{i=1}^n \frac{g(\xi_i)}{f_{\xi}(\xi_i)} \approx I. \quad (5)$$

Обобщение метода Монте-Карло

Пусть: $W = \frac{1}{n} \sum_{i=1}^n T_i$, ясно что $M W = I$, Сейчас мы получаем m значений W_1, W_2, \dots, W_m при помощи метод Монте-Карло. Легко видно, что $M \bar{W} = I$ где $\bar{W} = \frac{1}{m} \sum_{j=1}^m W_j$ и тогда следует новое приближение вычисления (1), значит:

$$\frac{1}{m} \sum_{j=1}^m w_j \approx I. \quad (6)$$

Сейчас приводим пример чтобы сравнить эти модели. Вычислим приближенно интеграл $I = \int_0^{\frac{\pi}{2}} \sin(x) dx$

точное значение этого интеграла известно: $I=1$. Промежуточные результаты из обычного метода Монте-Карло и нашего алгоритма, сведены в таблице 1.

Таблица 1. приближение вычисления I

n m	1 Монте-Карло	10	20	30	40
10	0,932013	1,016574	1,001245	0,991589	0,994749
20	1,165764	1,004910	1,038127	1,014690	0,974749
30	1,036637	0,987066	1,027111	1,001609	0,990790
40	0,963537	0,990585	1,027013	0,998816	1,005622
50	1,048903	1,02531	0,995575	0,994911	1,001449

Легко заметить, что можно использовать наш метод, не только для вычисления интегралов, но и для всех задач, использующих метод Монте-Карло.

Литература

1. Соболев И. М., Метод Монте-Карло // Наука, 1972.
2. Ермаков С. М., Метод Монте-Карло и смежные вопросы // Наука, 1971.

О радиусах разрешимости и регулярности задач распознавания

А.А. Черепнин

(Москва)

Рассматриваются классы задач распознавания с произвольной фиксированной системой универсальных ограничений [1]. В этой ситуации отдельные задачи из класса определяются фиксацией конкретных матрицы информации и информационной матрицы. Предполагается, что на множестве задач, то есть, по сути дела, на множестве пар матриц введена метрика.

В предположении о непустоте множества неразрешимых задач вводятся определения радиусов регулярности и разрешимости. Радиусом регулярности задачи называется расстояние от нее до ближайшей нерегулярной задачи, и, соответственно, радиусом разрешимости задачи называется расстояние от нее до ближайшей неразрешимой задачи [2].

Естественно, что радиус регулярности любой нерегулярной задачи оказывается равным нулю, как и радиус разрешимости любой неразрешимой задачи. Непосредственно из определений регулярности и разрешимости вытекает, что для любой задачи радиус регулярности не превышает радиус разрешимости.

В докладе отдельно рассматриваются задачи, у которых радиусы регулярности равны радиусам разрешимости и задачи, у которых радиусы разрешимости строго больше радиусов регулярности.

Для задач первого типа устанавливается требование к метрике, обеспечивающее справедливость утверждения о том, что информационная

матрица ближайшей для задачи неразрешимой (и нерегулярной) задачи совпадает с информационной матрицей исходной задачи.

Для задач второго типа вводится и обосновывается процедура построения конечной последовательности нерегулярных задач, находящихся в некотором смысле между исходной задачей и ближайшей к ней неразрешимой. При этом переход от задачи к задаче осуществляется путем изменения только одного элемента, либо матрицы информации, либо информационной матрицы.

Работа выполнена в рамках проекта “Алгебраические и комбинаторные методы математической кибернетики” Программы фундаментальных исследований Отделения математических наук РАН.

Литература

1. Рудаков К.В. Универсальные и локальные ограничения в проблеме коррекции эвристических алгоритмов классификации // Кибернетика. 1987. № 2. с. 30- 35.
2. Черепнин А.А. Об оценках регулярности задач распознавания и классификации // Журнал вычислительной математики и математической физики. 1993. №1, с. 155-159

О решетке функциональных сигнатур

Д.А. Черепнин

(Москва)

В теории универсальных и локальных ограничений для задач классификации введены специальные классы так называемых функциональных отображений матричных пространств друг в друга [1]-[3]. Эти классы определялись специальной структурой, называемой функциональной сигнатурой. На множестве функциональных сигнатур было введено отношение порядка [4], основанное на теоретико-множественном отношении порядка между соответствующими множествами отображений, что дало возможность сравнивать между собой функциональные сигнатуры или говорить о том, что они не сравнимы.

Оказывается, что множество функциональных сигнатур образует решетку, что дает возможность строить функциональную сигнатуру, которая была бы больше (или меньше) всех функциональных сигнатур из любого наперед заданного множества. Поскольку функциональные сигнатуры выражают ограничения на отображения, то речь идет о возможности получения дизъюнкции (конъюнкции) ограничений, выраженных отдельными функциональными сигнатурами. Становится возможным, имея ограничения на отображения, найти последующую (смягчив требования) или предшествующую (ужесточив требования), функциональную сигнатуру, которая была бы допустимой [1]-[3], т.е. сигнатуру, классы отображений

которой были бы замкнуты относительно суперпозиции и содержали бы тождественные отображения.

На множестве функциональных сигнатур вводятся и описываются специальные операции, а именно: инвариантные операции, операции перехода к последующей и предшествующей функциональной сигнатуре.

Конечной целью исследований является выделение на основе предварительного анализа прецедентной информации класса минимальных функциональных сигнатур, которые бы ей удовлетворяли. Для этого вводится понятие сложности несравнимых функциональных сигнатур, выявляются устойчивые области прецедентной информации (области на которых возможно использовать функциональные сигнатуры с малыми областями зависимости и с небольшим количеством функций).

Литература

1. Рудаков К.В. О некоторых классах алгоритмов распознавания (общие результаты). М. : ВЦ АН СССР, 1980. 66 с.
2. Рудаков К. В. О некоторых универсальных ограничениях для алгоритмов классификации. // Журнал вычислительной математики и математической физики. 1986. Т. 26 N 11. С. 1719-1729.
3. Рудаков К.В. О симметрических и функциональных ограничениях для алгоритмов классификации // Доклад АН СССР. 1987. Т.297 N 1. С.43-46.
4. Черепнин Д.А. Отношение порядка и эквивалентности для функциональных сигнатур, применяемых в обработке изображений и распознавании. // Журнал вычислительной математики и математической физики. 1995. Т.35 N10. С.1591-1599.

Неоднозначность разложения на множители, канонические системы счисления в квадратичных кольцах и параллельные алгоритмы вычисления свертки

В.М. Чернов
(Самара)

Одна цитата

"Оказывается, среди математиков существует глубоко укоренившаяся тенденция предполагать единственность разложения на простые. Эта тенденция, несомненно, навеяна опытом вычислений с обычными целыми числами.

Свидетельством силы этой тенденции служит использование Эйлером в его "Алгебре" единственности разложения для квадратичных целых, несмотря на контрпример

$$3 \cdot 7 = (4 + \sqrt{-5})(4 - \sqrt{-5}),$$

известный как ему, так и за сто лет до него Пьеру Ферма"[1].

Постановка проблемы

Наиболее существенным недостатком теоретико-числовых преобразований (ТЧП)

$$\hat{x}(m) = \sum_{n=0}^{N-1} x(n) \omega^{mn} \pmod{p} \quad (1)$$

представляющих собой основные дискретные преобразования в алгоритмах "безошибочного" вычисления дискретной свертки, умножения больших целых чисел и т.п., является то, что простые числа p с "дружественными" для машинной реализации свойствами модулярных операций (простые числа Мерсенна, Ферма, Голомба и т.п.) встречаются в натуральном ряду достаточно редко. Кроме того, в отличие от поля комплексных чисел, в конечном поле $\mathbf{GF}(p)$ существуют корни не любой степени N единицы, а только удовлетворяющие условию делимости $N \mid (p-1)$. Для чисел Ферма $f_t = 2^B + 1$, $B = 2^t$ это стеснительное, в общем случае, ограничение гарантирует существование структурно простых быстрых алгоритмов вычисления ТЧП. Наиболее просто реализуется ТЧП (1) при $\omega \equiv 2 \pmod{f_t}$. В этом случае модулярная версия алгоритма Кули-Гьюки (БПФ) реализуется без нетривиальных умножений. К сожалению, элемент $\omega \equiv 2 \pmod{f_t}$ является корнем степени $N = 2B$, что ограничивает максимальную длину преобразования Ферма, реализуемого без умножений, числом $N = 32$.

Это существенно ограничивает возможности применения ТЧП Ферма (и Мерсенна) в задачах обработки многомерной цифровой информации. Использование в качестве модулей ТЧП составных чисел Ферма доставляет серьезные трудности, связанные с существованием в модулярных кольцах по составным модулям делителей нуля и, как следствие, с необратимостью некоторых элементов соответствующих колец и/или с неортогональностью базисных функций ТЧП.

При распараллеливании вычислений в системе остаточных классов характерные преимущества "битовой" реализации арифметических операций в полях по модулям чисел Мерсенна и Ферма не наследуются для вычислений в полях по модулям целых делителей составных чисел Мерсенна или Ферма

$$m = 2^q \pm 1 = p_1 p_2 \dots p_d \quad (2)$$

Основные идеи

В докладе рассматриваются методы вычисления дискретной свертки, основанные на альтернативном разложении элементов колец целых алгебраических чисел на простые сомножители. В основе предложенных методов лежит следующая схема вычислений.

1. Кольцо классов вычетов $\mathbf{Z}/m\mathbf{Z}$ вкладывается в некоторое кольцо \mathbf{Z} , которое выбирается так, чтобы разложение (2) на простые элементы кольца \mathbf{Z} содержало только сомножители вида $p_j = \alpha_j^{k_j} \pm 1$.
2. Вычисление свертки проводится по обычной параллельной схеме с применением семейства дискретных преобразований в системе остаточных классов $(\text{mod } p_j)$ и с последующей реконструкцией значения свертки $(\text{mod } m)$ по китайской теореме об остатках.

3. Базисные функции $h_m^j(n)$ семейства этих преобразований выбираются в форме $h_m^j(n) = \alpha_j^{nm}$; если входные данные преобразований $(\text{mod } p_j)$ представлены в позиционной системе счисления "с основанием α_j ", то вычисление ТЧП не требует умножений.

Эффективность реализации предложенной схемы вычислений связана, естественно, с возможностью эффективной реализации вычислений при представлении данных в "нетрадиционных" системах счисления.

Канонические системы счисления в квадратичных полях

Следуя работам I.Kátaı [2]-[4], введем понятие редуцированной канонической системы счисления.

Определение. Целое алгебраическое число $\alpha = A + \sqrt{d}$ называется *основанием канонической системы счисления* в кольце \mathbf{S} целых элементов поля $\mathbf{Q}(\sqrt{d})$, если любой элемент этого кольца однозначно представим в форме конечной суммы

$$z = \sum_{j=0}^{k(z)} z_j \alpha^j,$$

где $z_j \in \mathbf{N} = \{0, 1, \dots, |\mathbf{Norm}(\alpha)| - 1\}$. Пара $\{\alpha, \mathbf{N}\}$ называется *канонической системой счисления* в кольце \mathbf{S} . Пусть \mathbf{J} - главный идеал в

кольце \mathbf{S} , α^* - образ основания α канонической системы счисления в фактор-кольце \mathbf{S}/\mathbf{J} . Пару $\{\alpha^*, \mathbf{N}\}$ будем называть *редуцированной канонической системой счисления* в кольце \mathbf{S}/\mathbf{J} .

В докладе показывается, что бинарными системами счисления обладают только кольца целых трех мнимых квадратичных полей, а именно:

(а) кольцо гауссовых чисел $\mathbf{S}_1 \subset \mathbf{Q}(i)$ при $\alpha = -1 \pm i$;

(б) кольцо $\mathbf{S}_2 \subset \mathbf{Q}(i\sqrt{2})$ при $\alpha = \pm i\sqrt{2}$;

(с) кольцо $\mathbf{S}_7 \subset \mathbf{Q}(i\sqrt{7})$ при $\alpha = 2^{-1}(-1 \pm i\sqrt{7})$.

Во всех перечисленных случаях подробно анализируются ТЧП-алгоритмы эффективного вычисления свертки при альтернативной факторизации модуля, равного $m_k = \mathbf{Norm}(\alpha^k \pm 1)$.

Литература

1. Эдвардс Г. Последняя теорема Ферма. Генетическое введение в алгебраическую теорию чисел, М.: Мир, 1980.
2. KátaI I., Szabó J., Canonical number systems for complex integers, // Acta Sci. Math., v.37, 1975, pp. 255-260.
3. KátaI I., Kovács B. Kanonische Zahlensysteme in der Theorie der quadratischen algebraischen Zahlen, //Acta Sci. Math., B.42, 1980, S. 99-107.
4. KátaI I., Kovács B. Canonical Number Systems in Imaginary Quadratic Fields, // Acta Math. Acad. Sci. Hungaricae, v.37, 1981, pp.159-164.

Мощности окрестностей в задачах выделения трендов

Ю.В. Чехович

(Москва)

Рассматривается задача синтеза обучаемых алгоритмов выделения трендов в конечных дискретных временных рядах (конечных плоских конфигурациях). В работе [1] была проведена формализация данной задачи и получены критерии разрешимости и регулярности задач выделения трендов. В [2,3] была рассмотрена проблема локализации алгоритмов выделения трендов, то есть была изучена возможность решения задачи в классе локальных алгоритмов, и получены критерии локальной разрешимости и локальной регулярности.

При обсуждении проблемы локализации считалось, что задана некоторая

система окрестностей на множестве всех конфигураций, в то время как вопрос выбора мощности окрестностей был оставлен в стороне. Тем не менее, проблема выбора мощности окрестности чрезвычайно актуальна. С одной стороны, разрешимая (регулярная) задача при некоторой мощности (размере) окрестностей может оказаться локально неразрешимой (в предельном случае, когда окрестностью точки является она сама, неразрешимой оказывается практически любая задача). С другой стороны, содержательная обоснованность и вычислительная сложность алгоритмов очевидным образом зависят от размеров окрестностей. Ясно, что для любой разрешимой (регулярной) задачи существует некоторый предельный размер (мощность) окрестностей, при которой задача все еще остается разрешимой (регулярной).

В настоящем докладе вводятся понятия мощности конфигурации и мощности окрестности, а также отношения порядка на множествах конфигураций и окрестностей. Приводятся теоремы о монотонности свойств локальной разрешимости и локальной регулярности относительно мощности окрестностей и приводятся описания алгоритмов построения оптимальных систем окрестностей, обеспечивающих локальную регулярность и локальную разрешимость.

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (проекты №№ 03-01-06459мас, № 02-01-00326).

Литература

1. Рудаков К.В., Чехович Ю.В. О проблеме синтеза обучаемых алгоритмов выделения трендов (алгебраический подход) // Прикладная математика и информатика, 2001 г. № 8. – С. 97-113.
2. Рудаков К.В., Чехович Ю.В. Алгебраический подход к проблеме синтеза обучаемых алгоритмов выделения трендов // Доклады Академии наук, 2003 г. том 388, № 1 с 1.-4.
3. Чехович Ю.В. Об обучаемых алгоритмах выделения трендов // Искусственный интеллект г. Донецк, 2002 г. № 2, с. 298-305.

Конструктивный метод обучения с учителем рекуррентного $\Sigma\Pi$ -нейрона

З.М. Шибзухов

(Нальчик)

Введение.

В данной работе рассматривается простейший класс искусственных рекуррентных нейронных сетей (РНС) построенных на основе единственного искусственного $\Sigma\Pi$ -нейрона с фиксированной глубиной связей по времени. Входные и выходные сигналы принимают значения в

произвольном числовом кольце, не содержащем делителей нуля. Для такой простейшей РНС предлагается конструктивный метод обучения с учителем по обучающим последовательностям входных сигналов и ожидаемых на выходе результатов функционирования сети. Данный метод позволяет по мере прохождения элементов предварительно упорядоченной обучающей последовательности постепенно наращивать структуру рекуррентного $\Sigma\Pi$ -нейрона и одновременно настраивать веса. В процессе обучения можно также использовать специальную процедуру минимизации рангов, входящих в структуру $\Sigma\Pi$ -нейронов мультипликативных подэлементов. Предлагаемый конструктивный метод обучения является адаптированным вариантом конструктивного обучения $\Sigma\Pi$ -нейронов, не содержащих обратных связей [1–4].

Рекуррентный $\Sigma\Pi$ -нейрон

Пусть $\mathbf{x}(t) = (x_1(t), \dots, x_n(t))$ — это поток векторов в дискретном времени $t = 1, 2, \dots$, $y(t)$ — это соответствующий ему поток значений. Будем считать, что $x_i(t) \in \mathbf{K}$, $1 \leq i \leq n$, $y(t) \in \mathbf{K}$, где \mathbf{K} — это кольцо, не содержащее делителей нуля. Рассмотрим алгебраический $\Sigma\Pi$ -нейрон [1,2] с обратными связями, на вход которого в каждый момент времени t поступает вектор $\mathbf{x}(t)$ и вектор выходных значений $\mathbf{y}(t) = (y(t-1), \dots, y(t-\ell))$ в моменты времени $t-1, t-2, \dots, t-\ell$:

$$y(t) = spn(\mathbf{x}(t), \mathbf{y}(t)), \quad (1)$$

где $\ell \geq 1$ — верхнее значение глубины связей по времени, $y(0) = y_0$, $y(-1) = y_{-1}$, ..., $y(1-\ell) = y_{1-\ell}$ — заданные начальные значения;

$$spn(\mathbf{x}(t), \mathbf{y}(t)) = out \circ sp(\mathbf{x}(t), \mathbf{y}(t)), \quad (2)$$

$$sp(\mathbf{x}(t), \mathbf{y}(t)) = \theta(\mathbf{x}(t)) + \sum_{k=1}^N w_k P(\mathbf{x}(t), \mathbf{i}_k) P(\mathbf{y}(t), \mathbf{t}_k), \quad (3)$$

где $\mathbf{i}_k \subseteq \{1, 2, \dots, n\}$, $\mathbf{t}_k \subseteq \{1, 2, \dots, \ell\}$, w_k — весовые коэффициенты, $\theta(\mathbf{x})$ — произвольная функция $\mathbf{K}^n \rightarrow \mathbf{K}$,

$$P(\mathbf{x}(t), \mathbf{i}_k) = \prod_{t \in \mathbf{i}_k} x_i(t),$$

$$P(\mathbf{y}(t), \mathbf{t}_k) = \prod_{\tau \in \mathbf{t}_k} y(t-\tau),$$

$p(\mathbf{x}(t), \emptyset) \equiv 1$, $p(\mathbf{y}(t), \emptyset) \equiv 1$, $out(s)$ — функция выхода $\mathbf{K} \rightarrow \mathbf{K}$.

Будем считать, что для любого $a \in \mathbf{K}$, любого $0 \neq b \in \mathbf{K}$, любого $y \in \mathbf{K}$ уравнение $out(a + wb) = y$ имеет решение $w_k \in \mathbf{K}$. В этом случае будем говорить, что уравнение $out(a + wb) = y$ разрешимо относительно w .

Формулы (1)–(3) описывают $\Sigma\Pi$ –нейрон с обратными связями или рекуррентный $\Sigma\Pi$ –нейрон.

Обучение с учителем рекуррентного $\Sigma\Pi$ –нейрона

Пусть на дискретном временном промежутке $[1, T]$ задана последовательность векторов входов $\mathbf{X} = \mathbf{X}[1, T] = \{\mathbf{x}(t)\}$ и последовательность выходных значений $\mathbf{Y} = \mathbf{Y}[1, T] = \{y(t)\}$. Требуется конструктивно обучить $\Sigma\Pi$ –нейрон по заданным последовательностям \mathbf{X} и \mathbf{Y} так, чтобы $y(t) \equiv \text{spn}(\mathbf{x}(t), \mathbf{y}(t))$ на $[1, T]$.

Конструктивность обучения $\Sigma\Pi$ –нейрона означает, что неизвестными являются не только веса, но и его структура, задаваемая при помощи мультииндексов.

При определенных предположениях относительно \mathbf{X} и \mathbf{Y} можно применить конструктивную процедуру рекуррентного обучения с учителем $\Sigma\Pi$ –нейрона [1,2].

Рассмотрим последовательность

$$\mathbf{XY} = \mathbf{XY}[1, T] = \mathbf{X} \cup \bigcup_{\tau=1}^{\ell} \mathbf{Y}[1-\tau, T-\tau] = \{(\mathbf{xy})(t)\},$$

где $(\mathbf{xy})(t) = \mathbf{x}(t) \cup y(t-1) \cup \dots \cup y(t-\ell)$, символ \cup обозначает операцию конкатенации векторов, $\mathbf{Y}[1-\tau, T-\tau] = \{y(t) : t = 1-\tau, 2-\tau, \dots, T-\tau\}$.

Для любого u обозначим

$$\bar{u} = \begin{cases} 1, & u \neq 0, \\ 0, & u = 0. \end{cases}$$

Для любого $\mathbf{u} = (u_1, \dots, u_K)$ обозначим $\bar{\mathbf{u}} = (\bar{u}_1, \dots, \bar{u}_K)$. Предположим, что выполняется следующее условие.

Условие 1. Для любой пары $t' \neq t''$ если $\overline{(\mathbf{xy})(t')} = \overline{(\mathbf{xy})(t'')}$, то $(\mathbf{xy})(t') = (\mathbf{xy})(t'')$ и $y(t') = y(t'')$.

Исключим из \mathbf{XY} и \mathbf{Y} совпадения вида $(\mathbf{xy})(t') = (\mathbf{xy})(t'')$ и $y(t') = y(t'')$, соответственно. Тогда найдется перестановка отсчетов дискретного времени $\tau : \{1, 2, \dots, T\} \rightarrow \{1, 2, \dots, T\}$, такая что $\mathbf{XY}_{\tau} = \{(\mathbf{xy})(\tau(t))\}$ является упорядоченной по нулям [2,4]. Пусть \mathbf{XY}_{τ} и \mathbf{Y}_{τ} это последовательности, которые получаются в результате такого переупорядочивания. Тогда можно применить конструктивную процедуру рекуррентного обучения $\Sigma\Pi$ –нейрона $\text{spn}(\mathbf{x}, \mathbf{y})$ по \mathbf{XY}_{τ} и \mathbf{Y}_{τ} [2–4].

Из теоремы о конструктивном обучении с учителем $\Sigma\Pi$ –нейрона по последовательностям векторов, упорядоченных по нулям [там же], вытекает

следующее утверждение.

Теорема 2. Если кольцо K не содержит делителей нуля, последовательность XU является упорядочиваемой по нулям, уравнение $out(a + wb) = y$ разрешимо относительно w , то можно конструктивно обучить рекуррентный $\Sigma\Pi$ -нейрон так, чтобы на $[1, T]$ выполнялось тождество $y(t) \equiv spn(x(t), y(t))$.

Работа выполнена при поддержке гранта РФФИ №01-01-00142, гранта №111 VI-го конкурса – экспертизы научных проектов молодых ученых РАН, Госконтракта №10002-251/OMN-2/024-115/120503-062.

Литература

1. Shibzoukhov Z.M. Constructive Training of Boolean-Valued Neural Networks of the Polynomial Type // Pattern Recognition and Image Analysis. 2001. Vol. 11, №1. – PP.95–96.
2. Шибзухов З.М. Рекуррентные методы конструктивного обучения нейронных сетей из логико-арифметических $\Sigma\Pi$ -нейронов // Нейрокомпьютеры: разработка и применение. 2002. №5. – С.50–57.
3. Шибзухов З.М. Рекуррентный метод конструктивного обучения алгебраических $\Sigma\Pi$ -нейронов и $\Sigma\Pi$ -нейромодулей // Доклады РАН. 2003. Т.388, №2. – С.174–176.
4. Шибзухов З.М. Рекуррентный метод конструктивного обучения некоторых сетей алгебраических $\Sigma\Pi$ -нейронов и $\Sigma\Pi$ -нейромодулей // Журнал вычислительной математики и математической физики. 2003. Т.43, №8. – С. 1298–1310.

Структуры распознающих систем на основе стохастической геометрии

Л.А. Шульга, Н.Г. Федотов
(Пенза)

В докладе рассматривается характер влияния специфики решаемой задачи на структуры распознающих систем, базирующихся на стохастической геометрии.

Отличительной чертой систем такого класса является применение методов стохастической геометрии и функционального анализа на этапе генерации признаков распознавания. Характерной особенностью группы рассматриваемых признаков, названных триплетными, является представление каждого из них в виде последовательной композиции трех функционалов $\Pi(F) = T \circ P \circ \Theta(F \cap l(p, \theta, t))$, где p и θ - нормальные координаты сканирующей прямой l , а t - естественная система координат, связанная с ней, а F - исходное изображение.

Ключевым элементом теории является Тгасе-преобразование, связанное со сканированием изображения по сложным траекториям [1]. Результатом Тгасе-преобразования является промежуточный образ или Тгасе-матрица.

Проведено исследование реакции Тгасе-образа, полученного в процессе сканирования оригинального изображения множеством случайных прямых, по отношению к группе движений (поворотам, переносам) и масштабным преобразованиям изображений [3]. В работе [3] показано, что Тгасе-преобразование является удобным инструментом для изучения перемещения объектов, определения числа объектов и их взаимного расположения.

Последующее вычисление признака заключается в последовательной обработке столбцов матрицы с помощью функционала \mathbf{P} , который назван диаметральным функционалом. Результат действия диаметрального функционала $h(\theta) = \mathbf{P}g(\theta, p)$ к Тгасе-матрице - 2π - периодическая кривая. Заключительный этап формирования нового признака распознавания изображений состоит в действии функционала Θ на функцию $h(\theta)$, т.е. признак распознавания есть $\Pi(F) = \Theta h(\theta)$. Сам функционал Θ назван круговым, так как область определения кривой 2π .

Структура признака распознавания представляет собой последовательную композицию трех функционалов $\Theta, \mathbf{P}, \mathbf{T}$, действующих, соответственно, по переменным θ, p и t :

$$\Pi(F) = \Theta(h(\theta)) = \Theta \circ \mathbf{P}(g(\theta, p)) = \Theta \circ \mathbf{P} \circ \mathbf{T}(f(\theta, p, t)).$$

Исследования признаков распознавания нового класса показали:

- рассмотренные методы формирования признаков распознавания дают возможность генерировать большое число, фактически тысячи, новых признаков изображений, что доказывает их ценность при решении задач распознавания объектов со множественной структурой классов (распознавание иероглифов или текстур);
- генерация признаков имеет достаточно простую реализацию и может осуществляться автоматически, что особенно ценно на этапе проектирования распознающих систем;
- трехфункциональная структура новых признаков распознавания применима для обработки цветных и полутоновых изображений.

Анализ структуры признаков позволил выявить порядка 200 новых функционалов из различных областей математики, теории вероятностей, математической статистики, теории рядов и фрактальной геометрии и перенести свойства математического аппарата данных областей на признаки распознавания.

Следует заметить, что генерация столь большого числа новых признаков распознавания используется на этапе обучения системы, использование такой системы признаков на этапе распознавания неизбежно приведет к

трудоемким вычислительным затратам, поэтому в работе [2] предложено осуществлять минимизацию признаков пространства с целью выявления набора наиболее эффективных признаков распознавания на основе коэффициентов разложения Карунена-Лоэва.

Схема распознающей системы, использующей автоматическую компьютерную генерацию признаков распознавания, основанных на стохастической геометрии, и селекцию этих признаков по показателю эффективности, представлена на рисунке 1.

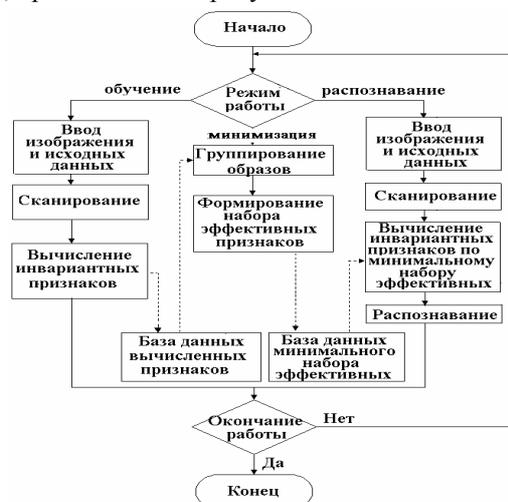


Рис. 1. Схема распознающей системы данного класса.

Решение некоторых прикладных задач распознавания образов заставляет отклониться от вышеприведенной схемы. Наиболее характерная модификация структуры распознающей системы возникает при решении задач технической дефектоскопии, в частности, дефектоскопии сварных соединений [см. статью Н.Г. Федотова, Т.В. Никифоровой в настоящем сб.]. Характерной особенностью изображений дефектов сварных соединений, усложняющих решение задачи распознавания, является значительная вариабильность их по форме, геометрическим размерам, уровню зашумленности при относительно небольшом числе распознаваемых классов или образов, регламентированном ГОСТом на контроль сварных соединений по результатам радиографического контроля.

Доказано, что на основе композиции трех функционалов можно не только формировать признаки распознавания образов, отражающие их геометрические параметры, особенности формы, структурные свойства, но и реализовать нелинейную фильтрацию изображений. Варьируя свойства функционалов, входящих в композицию, можно осуществить нелинейную фильтрацию с целью уменьшения зашумленности, квантования, утончения,

полигональной аппроксимации изображений дефектов.

Следует подчеркнуть, что при таком подходе нелинейная фильтрация и вычисление признаков осуществляется в одной технике, что позволяет объединить предварительную обработку изображений и вычисление признака в одном такте работы сканирующей системы. Это приводит к выигрышу в быстродействии системы.

Эффективная предварительная обработка позволяет понизить количество признаков. На структуре распознающей системы это отразится так, что в силу исчезновения необходимости в минимизации признакового пространства, будет исключен блок минимизации на основе разложения Карунена-Лоэва. Одновременно произойдет значительное упрощение процедуры автоматической генерации признаков и решающей процедуры, что приведет, в частности, к исчезновению необходимости создавать соответствующие базы данных.

Литература

1. Федотов Н.Г. Методы стохастической геометрии в распознавании образов. - М.: Радио и связь, 1990.
2. Шульга Л.А., Федотов Н.Г. // Компьютерная генерация триплетных признаков распознавания образов. Искусственный интеллект, 2002. - №2. - С. 306-314.
3. Nikolay G. Fedotov, Lyudmila A. Shulga // New Geometric Transform Based on Stochastic Geometry in the Context of Pattern Recognition, Proc.13th Scandinavian Conference on Image Analysis, SCIA 2003, Springer, 2003, P. 148-155.

О формировании набора эталонов в базах данных

С.А. Яковлев

(Москва)

В работе предложено учитывать в базовой концепции распознавания отношение частичной упорядоченности, что позволяет подойти к решению таких актуальных задач, как задача формирования и обновления эталонов в базах данных.

На первых этапах развития теории распознавания проблему в наиболее общем виде можно было понимать следующим образом. Имеется формальное описание набора объектов, характеризующих определенные явления или классы. Дано также описание объекта неизвестной принадлежности. Необходимо определить или классифицировать объект по его описанию. Формализация проблемы позволила обосновать специализированные алгоритмы распознавания, работающие в различных функциональных, в том числе метрических пространствах. Быстро расширился круг областей применения методов распознавания – техническая

и медицинская диагностика, геологоразведка, распознавание звуковых и зрительных образов и др.

В дальнейшем теория распознавания из прикладной отрасли науки превратилась в фундаментальную дисциплину. Всякое решение есть выбор одной из альтернатив. Поэтому процедура принятия решения всегда может быть рассмотрена с позиции классификации. Теория распознавания, изучающая механизмы выбора, определилась как общенаучное методологическое направление. Получили развитие:

- статистические методы распознавания, прогнозирования, восстановления зависимостей;

- алгебраические методы исследования распознающих и решающих операторов;

- структурные методы построения и обучения распознающих устройств и др.

При этом в первом приближении не менялась базовая концепция, основанная на неизменности классов, представительности эталонов и функции близости объектов как основы для принятия решений.

В связи с повсеместным распространением информационных технологий в науке и технике одним из основных способов сохранения массовой информации стали базы данных. По существу, каждая единица информации в базе может рассматриваться как объект – представитель некоторого класса. При изучении процесса в реальном времени можно заметить, что накопление информации часто сопровождается повышением значимости новых объектов и потерей значимости старых. Таковы многие технические, документные, товарные, клиентские, фармакологические и другие базы. Особенности этого явления требуют учета по меньшей мере двух новых факторов:

- внешнее к базе ранжирование объектов, позволяющее отличать эталоны;

- внутреннее упорядочение объектов базы, позволяющее обновлять эталоны.

При формализации явления замечаем, что в функциональном пространстве описаний объектов (для распознавания достаточно функции близости или метрики) необходимо определить отношение частичной упорядоченности (этого обычно достаточно для обновления набора эталонов).

В заключение отметим, что введение отношения порядка в базовую концепцию распознавания позволяет осуществлять поиск объектов, обладающих существенным отличием от эталонов.

Синтез смешанных логических тестов на основе ускоренных шагово-циклических алгоритмов спуска

А.Е. Янковская

(Томск)

Введение

Актуальность применения тестовых алгоритмов распознавания образов не вызывает сомнения [1], поскольку эти алгоритмы позволяют учитывать информацию, заключенную в комбинациях значений признаков, не требуют сильных предположений относительно свойств исследуемого объекта и позволяют успешно решать задачу распознавания при наличии относительно малой обучающей выборки по каждому образу в большом признаковом пространстве и при большом количестве образов.

Обоснованность, эффективность и перспективность применения смешанных логических тестов, представляющих собой оптимальное сочетание безусловных и условных составляющих [2] связана с возможностью последовательного извлечения информации об исследуемом объекте для условной составляющей смешанного теста, с преимуществами использования безусловных тестов при построении решающих правил, а также с целесообразностью применения смешанных тестов при организации интеллектуального интерфейса (построения опросника).

Ускоренные алгоритмы синтеза тестов позволяют за то же самое время построить большее количество тестов, провести их целенаправленный отбор, и тем самым повысить точность итогового распознавания на основе процедуры голосования на множестве тестов. Предлагаемые в докладе ускоренные шагово-циклические алгоритмы синтеза смешанных логических тестов базируются на алгоритмах спуска [3], используемых для построения тестов как при проектировании и перепроектировании устройств логического управления, так и при тестовом распознавании образов [3-5].

Постановка задачи

Для троичной матрицы Q , строки которой сопоставлены объектам (состояниям, ситуациям, условиям), столбцы – признакам, а элементы ее принимают значения из множества $\{0,1,-\}$, где символ "-" означает, что безразлично или неизвестно значение данного признака для данного объекта, заданы каким-либо образом (матрично либо функционально) требования, называемые в дальнейшем требованиями различения, которые должны быть обеспечены матрицей Q . Нужно построить матрицу Q' , содержащую минимальное или безызбыточное число столбцов матрицы Q и удовлетворяющую заданным требованиям различения.

Требования различения представляются матрицей различения R , столбцам которой сопоставлены классификационные признаки, а столбцам матрицы Q – характеристические признаки. Множество всех

неповторяющихся строк матрицы R сопоставлено множеству выделенных образов. Элементами образа являются объекты, представленные строками матрицы Q, сопоставленными одинаковым строкам матрицы R.

Ускоренные шагово-циклические алгоритмы

В основе ускоренного шагово-циклического алгоритма спуска, используемого для синтеза смешанных логических тестов, лежит теорема об оценке минимальной длины теста, доказательство которой очевидно.

Теорема 1. $d \geq \lceil \log_2 n \rceil$, где d – длина теста, n – число образов, a] b [– наименьшее сверху целое к b .

Следствие. Применение теоремы 1 позволяет сократить объем перебора (V) при оценке промежуточных решений по длине безыбыточного теста на величину w , где $w \geq d \cdot V/t$, а t – число столбцов матрицы Q.

Шагово-циклические алгоритмы основаны на 3-х подходах [4]: 1) с построением безыбыточной матрицы импликаций U', задающей различимость объектов из разных образов; 2) с частичным построением матрицы импликаций U'; 3) без построения матрицы импликаций U'.

Отметим, что строки матрицы импликаций U' сопоставлены парам образ-образ, образ-объект и объект-объект из разных образов. Строка матрицы U' представляет значение одной из 3-х вектор функции различения:

$$f(K_i, K_j) = z(K_i)\bar{z}(K_j) \vee \bar{z}(K_i)z(K_j) = z(K_i) \oplus z(K_j), \quad (1)$$

$$f(K_i, a) = z(K_i)\bar{z}(a) \vee \bar{z}(K_i)z(a) = z(K_i) \oplus z(a), \quad (2)$$

$$f(a, b) = z(a)\bar{z}(b) \vee \bar{z}(a)z(b) = z(a) \oplus z(b), \quad (3)$$

где a, b – объекты из разных образов, $z(a)$ – описание a -го объекта, K_i – устойчивые признаки внутри i -го образа, $z(K_i)$ – троичный вектор, компоненты которого принимают значения одноименных компонент описаний объектов из K_i .

В рамках 1-го подхода на основе шагово-циклических алгоритмов [3,4], заключающихся в выделении неисключаемых подмножеств столбцов из матриц Q, U', сопоставленных обязательным признакам (безусловной составляющей смешанного теста) – ядру B^+ ($B^+ \subseteq B$, где B – множество столбцов матрицы Q, за исключением столбцов, сопоставленных константным, неинформативным, альтернативным и зависимым признакам) применяется процедура добавления столбцов к множеству B^+ . На первом шаге итерации на основе теоремы 1 добавляется v столбцов, где $v = d - |B^+|$, а $|B^+|$ – мощность множества $|B^+|$; а на последующих – по одному столбцу, сопоставленному признаку с наибольшим весовым коэффициентом и проверкой на обеспечение всех условий различения (построения безыбыточного теста).

Признаки, сопоставленные добавляемым столбцам, представляют собой

условную составляющую смешанного теста, реконструируемую с целью получения на каждом ярусе дерева смешанного теста наибольшего коэффициента разделения [5]. Следующий смешанный тест синтезируется из предыдущего путем исключения из него признака, не являющегося обязательным, и поочередного добавления тестов признаков, сопоставленных столбцам из множества $B \setminus B^+$, и не используемых при построении l предыдущих тестов, где l – определяется экспериментально. Критерий останова синтеза тестов приводится в докладе.

Аналогично с применением теоремы 1 модифицирован синтез смешанных логических тестов с применением генетических преобразований.

Рамки доклада не позволяют представить алгоритмы синтеза смешанных логических тестов на основе ускоренных шагово-циклических алгоритмов спуска с применением и без применения генетических преобразований применительно к 2-у и 3-у подходам. Отметим, что ускорение достигается на основе использования теоремы 1 и следствия на величину не менее w .

Заключение

Отсутствие необходимости оценивания промежуточных решений на обеспечение условия безызбыточности при построении смешанных тестов до достижения длины теста - величины d приводит к сокращению перебора, а следовательно, к повышению эффективности созданных на их базе интеллектуальных систем тестового распознавания образов.

Работа поддержана РФФИ, проекты № 01-01-00772 и № 01-01-01050.

Литература

1. Журавлев Ю.И., Гуревич И.Б. Распознавание образов и анализ изображений // Искусственный интеллект, кн.2, модели и методы / Под ред. Д.А. Поспелова. – Москва "Радио и связь", 1990. – С.149-190.
2. Yankovskaya A.E. Design of Optimal Mixed Diagnostic Test With Reference to the Problems of Evolutionary Computation// Proceedings of the First International Conference on Evolutionary Computation and Its Applications (EVCA'96). – Moscow, 1996. – Pp. 292-297.
3. Янковская А.Е. Алгоритмы спуска при решении некоторых задач синтеза дискретных устройств и их приложения// Теория дискретных управляющих устройств. – М.: Наука, 1982. – С. 206-214.
4. Янковская А.Е. Логические тесты и средства когнитивной графики в интеллектуальной системе// Новые информационные технологии в исследовании дискретных структур: Доклады 3-ей Всерос. конф. с междунар. участием. – Томск: Изд-во СО РАН, 2000. – С. 163-168.
5. Янковская А.Е., Кузоваткин А.Н. Принятие решений в интеллектуальном инструментальном средстве ИМСЛОГ 2002 на основе смешанных диагностических тестов// Информационные системы и технологии (ИСТ-2003). Материалы международной конференции. Том 3. – Новосибирск: изд-во НГТУ, 2003. – С. 182-186.

Сравнительный анализ методов получения весовых коэффициентов признаков в задаче распознавания образов

А.Е. Янковская, С.И. Колесникова

(Томск)

Введение

В тестовых распознающих системах [1] весьма актуальна задача вычисления весовых коэффициентов характеристических признаков. Предложенная в [2] для тестовых алгоритмов мера важности признака (информационный вес), как отношение числа вхождений признака во все безыбыточные (тупиковые) тесты к числу всех безыбыточных тестов, логична, интуитивно прозрачна и легко интерпретируема. Эта мера важности пригодна для задач распознавания образов малой размерности, так как количество безыбыточных тестов при числе признаков, равном несколько десятков, может быть весьма большим [3] и нахождение всех безыбыточных тестов становится нереальным при применении даже современных компьютерных технологий. Приведенный в [3] метод вычисления весовых коэффициентов признаков на основе разделяющей способности признаков весьма прозрачен, прост и эффективен при репрезентативной выборке.

В данной работе приводится метод количественной оценки важности признаков [4], дается сравнительный анализ методов получения весовых коэффициентов признаков и иллюстративный пример.

Краткое изложение сравниваемых методов, иллюстративный пример

Поскольку формула для вычисления весовых коэффициентов признаков на основе разделяющей способности приведена в [3], реализована в интеллектуальных инструментальных средствах, основанных на тестовом распознавании образов [5], и апробирована на интеллектуальных системах [6], созданных на базе инструментальных средств, при решении реальных задач в различных проблемных областях, остановимся на количественной оценке важности целей [4], понимая при этом под важностью целей – важность признаков.

Рассмотрим метод нахождения математических ожиданий весовых коэффициентов признаков, изложенный в [4] для оценки целей многоцелевой планируемой операции применительно к задаче распознавания образов. Метод [4] основан на выборе в качестве “точечных оценок” \bar{z}_i их значений в центре тяжести области допустимых значений Ω , то есть математическое ожидание значений $z_i, i = \overline{1, n}$, когда случайный вектор $z = (z_1, z_2, \dots, z_n)$ равномерно распределен в Ω .

Отметим, что в [4] установление предпочтения отведено ЛПР.

Обозначим через $P = [P_1, P_2, \dots, P_n]$ множество входящих в тест признаков, упорядоченных и перенумерованных в порядке убывания их важности [4]:

$$P_1 \succ P_2 \succ \dots \succ P_n \quad (1)$$

Отметим, что в [4] установление предпочтения отведено ЛПР.

Дополнительно к (1) данный метод требует известные результаты сравнения с точки зрения их предпочтительности отдельного признака P_i и «комплексного» (следуя терминологии [4]), представляющего собой объединение двух следующих P_{i+1}, P_{i+2} , $P'_i = P_{i+1} \cup P_{i+2}, i = \overline{1, n-2}$, то есть для каждой пары (P'_i, P_i) имеет место одно из следующих трех соотношений:

$$P'_i \succ P_i, P_i \sim P'_i, P_i \succ P'_i, i = \overline{1, n-2} \quad (2)$$

Применительно к задаче оценки весовых коэффициентов признаков алгоритм [4] включает 2 этапа: 1) нахождение коэффициентов признаков P_{n-2}, P_{n-1}, P_n , обозначенных через $\bar{z}_{n-2}, \bar{z}_{n-1}, \bar{z}_n$; 2) нахождение коэффициента \bar{z}_i признака P_i с учетом заданного предпочтения относительно признака P_i и $P'_i = P_{i+1} \cup P_{i+2}, i = \overline{1, n-3}$.

Рассмотрим иллюстративный пример: пусть задана двоичная матрица описаний объектов (Q) в пространстве 4-х характеристических признаков и одностолбцовая матрица различий (R), строки которой сопоставлены строкам матрицы Q, а столбец – классификационному признаку, разбивающему объекты на классы эквивалентности (6 образов).

$$Q :: \begin{matrix} 1 & \begin{bmatrix} 1 & 1 & 1 & 1 \\ 2 & 0 & 0 & 0 & 1 \\ 3 & 1 & 0 & 0 & 1 \\ 4 & 0 & 0 & 0 & 1 \\ 5 & 1 & 0 & 1 & 1 \\ 6 & 1 & 0 & 1 & 0 \\ 7 & 0 & 1 & 1 & 0 \\ 8 & 0 & 1 & 1 & 1 \end{bmatrix} \\ R :: \begin{matrix} 1 & \begin{bmatrix} 1 \\ 2 \\ 2 \\ 3 \\ 2 \\ 5 \\ 3 \\ 6 \\ 4 \\ 7 \\ 5 \\ 8 \\ 6 \end{bmatrix} \end{matrix}$$

Полученные методом [3] весовые коэффициенты признаков, равны 0,56; 0,6; 0,6; 0,48, а по методу [4] - 0,225; 0,376; 0,274; 0,125 соответственно.

Заключение

Результаты сравнения двух методов [3,4] получения весовых коэффициентов признаков говорят о безусловном преимуществе по точности вычисления коэффициентов по методу [3] по сравнению с методом [4], поскольку с какими бы значениями весовых коэффициентов

характеристических признаков с теми же предпочтениями для различных матриц Q и R с одним и тем же числом столбцов матрицы Q мы не брали, получим по методу [4] одинаковые значения весовых коэффициентов признаков. Как отмечено в [4], условия (1), (2) являются минимальной информацией, которая дает возможность прогнозировать характер изменения количественных значений коэффициентов важности целей (признаков), двигаясь от более предпочтительного к менее предпочтительному. Отметим, что метод [4] удобен для оценки коэффициентов важности целей (признаков) при использовании шкалы равных интервалов (интервальной шкалы [7]) или шкалы порядка. При использовании шкалы пропорциональных оценок [7] (наиболее предпочтительной в принятии решений) метод [4] менее удобен, т.к. при одинаково установленном предпочтении будет выдавать одинаковые оценки весов несмотря на существенные количественные различия между ними.

В заключение отметим о целесообразности сравнения методов [2,3] получения весовых коэффициентов признаков на реальных задачах.

Работа поддержана РФФИ, проекты № 01-01-00772 и № 01-01-01050.

Литература

1. Журавлев Ю.И., Гуревич И.Б. Распознавание образов и анализ изображений // Искусственный интеллект в 3-х кн. Кн 2. Модели и методы: Справочник / Под ред. Д.А.Поспелова. - М: Радио и связь, 1990. С. 149-190.
2. Дмитриев А.Н., Журавлев Ю.И., Кренделев Ф.П. О математических принципах классификации предметов и явлений // Дискретный анализ. – Н-ск: изд-во Институт математики СО АН СССР, 1966. Вып.7. – С. 3-15.
3. Yankovskaya A.E. Test Pattern Recognition with the Use of Genetic Algorithms// Pattern Recognition and Image Analysis. – 1999. – Vol. 9, No. 1. – Pp. 121-123.
4. Шахнов И.Ф. Количественная оценка важности целей//Известия РАН. Теория и системы управления. – 2003. – №1.– С.78-86.
5. А.Е. Yankovskaya, A.I. Gedike, R.V. Ametov, A.M.Bleikher IMSLOG-2002 Software Tool for Supporting Information Technologies of Test Pattern Recognition // Pattern Recognition and Image Analysis. – 2003. – Vol. 13, No. 2. – Pp. 243-246.
6. Янковская А.Е., Гедике А.И., Аметов Р.В. Конструирование прикладных интеллектуальных систем на базе инструментального средства ИМСЛОГ-2002// Новые информационные технологии в исследовании сложных структур. Вестник Томского государственного университета. Приложение. № 1(II). Сентябрь 2002. Доклады IV Всероссийской конф. с междуна. участием. – Томск, 2002. – С. 185-190.
7. Ларичев О.И. Теория и методы принятия решений, а также Хроника событий в Волшебных странах: Учебник. – М.: Логос. 2002 – 392с.

II. Прикладные задачи и системы распознавания

Многоуровневая система распознавания рукописных форм

К.Р. Айда-заде, С.Г. Талыбов, Э.Э. Мустафеев

(Азербайджан, Баку)

В системах автоматического ввода и распознавания рукописных форм для увеличения надежности считывания информации широко используются справочные данные относительно определенных или всех полей формы. Эти базы данных, содержащие множества возможных (допустимых) значений реквизитов полей формы, которые существенно ограничены и заранее известны, используются для проверки результатов распознавания. В существующих они используются после этапа распознавания, и он не дает существенного выигрыша в скорости распознавания, а служит только для проверки результатов распознавания. Использование этих справочных данных непосредственно в процессе распознавания существенно сужает количество возможных вариантов, что естественно и ускоряет время распознавания.

Ниже предлагается подход, реализованный нами в системе распознавания рукописных форм, суть которого заключается в использовании:

- 1) баз знаний относительно части или всех полей рукописной формы, содержащих четкую и альтернативную нечеткую информацию;
- 2) многоуровневой (многометодной) системы распознавания, уровни которого различаются по времени и трудоемкости распознавания, с возможностью осуществления запроса на поиск по базе знаний с нечеткой информацией на каждом этапе распознавания и прекращения текущего процесса распознавания при удачном поиске в базе.

Для создания базы знаний относительно какого-либо поля рукописной формы, предварительно все множество распознаваемых образов (объектов) разделяются на классы с сильной внутренней и слабой межклассовой корреляцией, и каждому классу присваивается уникальный идентификатор, однозначно определяющий этот класс. Затем в этой справочной базе создается альтернативное поле, где вместо распознаваемых объектов используются идентификатор класса, к которому принадлежит этот объект.

Многоуровневая (многометодная) система распознавания строится таким образом, что на первых уровнях используются быстрые алгоритмы определения принадлежности данного образа к конкретному классу и алгоритмы определения элемента внутри класса, а на следующих уровнях

относительно неопознанных объектов используются точные, но трудоемкие по времени алгоритмы глубокой обработки. Специфика предлагаемого подхода заключается в том, что при распознавании на каждом уровне осуществляется поиск по базе знаний и при нахождении уникального элемента, не важно – четкого или нечеткого, за результат распознавания на этом этапе берется соответствующий элемент.

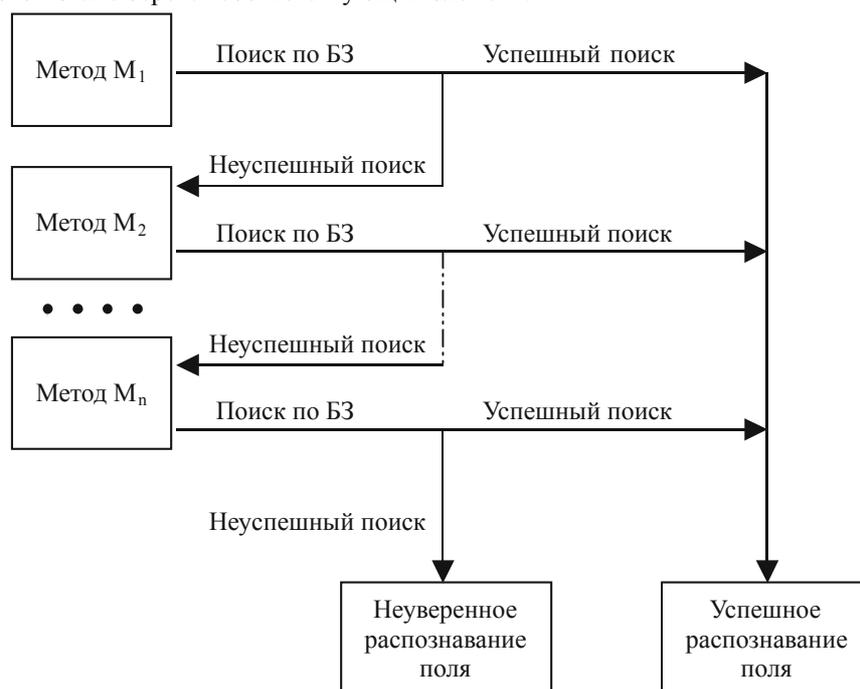


Рис. 1. Структура системы распознавания рукописных форм.

Преимущество предлагаемого подхода заключается в том, что при распознавании полей формы со справочными данными, значение поля определяется не распознаванием всех символов, а, чаще всего, определением всего лишь нескольких, достаточных для однозначного определения значения поля по справочной базе. Особенностью этого метода является и то, что использование справочной базы и нахождение нужного значения возможно уже на первом уровне распознавания при нечеткой информации о распознаваемом поле. Конечно, важное значение приобретает содержание самой базы знаний относительно полей формы, в которой одному четкому образу может ставиться в соответствие различные нечеткие прообразы, построенные по ассоциативному принципу [1].

Предположим, что в системе распознавания заложены n-методов

(алгоритмов) распознавания: M_1, \dots, M_n , различающиеся глубиной обработки, сложностью алгоритмов, временем работы и упорядоченные в порядке возрастания указанных показаний.

В процессе распознавания полей формы на первом уровне наиболее «быстрыми» алгоритмами класса M_1 определяют принадлежность данных изображений символов к одному из известных классов. Затем, по уверенно определенным классам выполняют поиск по альтернативному ключевому полю в базе знаний, содержащей возможные варианты нечетких прообразов, составленных по ассоциативному принципу [1]. Если удалось найти уникальную запись, то результатом распознавания будет приниматься значение основного поля. Надо отметить, что при этом дальнейшее точное распознавание объектов поля прекращается. Если не удалось найти такого элемента или таких элементов нашлось несколько, то результаты распознавания передаются на второй уровень. Здесь делается попытка более «тонкими» методами, алгоритмами точно определить символы внутри класса и, как и в предыдущем уровне, выполняется поиск в нечеткой базе знаний по уверенно распознанным символам, но по основному ключевому полю. Наиболее подходящий элемент берется за результат распознавания. Если опять не удалось найти нужную запись, то результаты распознавания передаются на следующий уровень более глубокой обработки. На этом уровне неуверенно распознанные на предыдущих уровнях символы при помощи методов структурного анализа однозначно определяются и опять производится поиск по базе. Результат поиска берется за значение поля, но если опять поиск не дал результатов, поле формы отмечается как не полностью распознанным и нуждается в проверке со стороны оператора (рис. 1).

Ясно, что эффективность всей системы распознавания будет существенно зависеть от полноты базы знаний, которая может пополняться по результатам эксплуатации системы для конкретной предметной области, т.к. желательным является создание объектно-ориентированных баз знаний.

Приведенный доклад иллюстрируется демонстрацией разработанной системой распознавания рукописных форм, ориентированной на азербайджанский язык и использование соответствующих баз знаний.

Литература

1. К.Р.Айда-заде, Э.Э.Мустафаев. Ассоциативные многоуровневые системы распознавания объектов // Известия НАН Азербайджана, №3, 2001
2. FineReader Forms 4.0 Forms. Руководство пользователя. АBBYY Software House. Москва, 1998.

Распознающие модели в технической диагностике объекта управления

Э.М. Алиев, Н.Т. Сотиволдиев, А.Х. Шералиев
(Ташкент)

Протекаемые процессы в объекте управления (ОУ) могут оказаться настолько сложными и недоступными для контроля, что построение не только замкнутого управления, но и организация эффективной системы в режиме советчика становится проблематичной [1, 2]. В связи с этим появляется необходимость разработки распознающей модели, позволяющей на основе ретроспективной информации об ОУ построить его математическую модель в терминах методов распознавания образов с учетом управляющих воздействий. Параметры объекта могут быть измерены как в любые дискретные моменты, так и непрерывно. Необходимо отметить наличие и таких параметров, которые могут быть оценены визуально или же определены оператором на основе многолетнего его опыта. Если здесь внести понятие основного параметра, необходимого для построения систем управления, то его значение с определенной точностью в любой момент времени можно получить с помощью непрерывного измерения востепенных параметров. Таким образом, в нашей постановке рассматриваются модели основного параметра, т.е. ретроспективная модель ОУ, созданная на основе использования накопленного информационного базиса по управлению этим объектом. Необходимость такого подхода вызвана тем, что современные сложные технические объекты часто не могут быть описаны достаточно четко и всесторонне математическими уравнениями или, если их и описать, то это приводит к колоссальным вычислительным процедурам и их применение в реальном масштабе времени становится проблематичным и дорогостоящим инструментом. Этапы реализации распознающей модели объекта управления выглядят следующим образом:

-на основе ретроспективных характеристик организуется таблица обучения, т.е. априорные входные и выходные параметры, а также управляющие воздействия представляются в виде реализаций

$$Y_j^r = f(x_{j1}^2, x_{j2}^2, \dots, x_{jn}^2, u_{j1}^2, u_{j2}^2, \dots, u_{jq}^2) \quad (1)$$

где $i = \overline{1, n}$, Y_j^r - j -тая реализация объекта управления, $r = \overline{1, p}$ - r -тый класс в таблице обучения, $j = \overline{1, m}$ - q -тое управляющее воздействие j -той реализации объекта, x_{ji} - i -тый параметр j -той реализации объекта.

В (1) входят как параметры реализации, так и управляющие воздействия ОУ, обеспечивающие тот или иной ход управления в смысле достижения

заданного показателя качества.

Следующим этапом реализации модели ОУ является организация вектора X^c - исходного состояния представляемого к обучению ОУ, т.е.

$$X^c = (x_1^c, x_2^c, \dots, x_n^c), \quad (2)$$

составляющие $x_i^c (i = \overline{1, n})$ представляют собой данные показателей датчиков, лабораторных анализов и других регистров в реальном масштабе времени, а также данные визуального наблюдения за ходом технического, технологического или производственного процессов, вносимые тем или иным способом непосредственно человеком-оператором.

Эти данные могут принимать свои значения из множеств: $\{0,1\}$, $\{0, 1, -\}$, $\{1, 2, \dots, k\}$, $[a, b]$, $\{\mu\}^i$.

Таким образом, здесь необходима разработка или применение с корректировкой на ОУ известного алгоритма, реализующего в основном задачу, сформулированную следующим образом: при сравнении ретроспективных объектов с исходным необходимо найти такой объект в (1), чтобы он был близок по характеристикам вектора (2) и тогда можно применять к исходному объекту траектории управления этого объекта и эти траектории приведут к близким конечным результатам.

Теперь, если обучающая таблица разделена на несколько классов (например, хорошее протекание процесса, удовлетворительное, плохое – аварийное), то дальнейшая задача разделяется на несколько подзадач. В-первых, отнести исходное состояние ОУ по своим характеристикам к близкому ему классу. Если это аварийное состояние, то необходимо провести настройку параметров таким образом, чтобы вывести его на уровень «удовлетворительного» класса, а затем и «хорошего». В дальнейшем в этом классе можно найти близкий к исходному обучающий объект и управление осуществлять по данным этого объекта.

Методы, реализующие данный подход, в зависимости от требований к ОУ, основаны на методах распознавания образов и могут являться методами потенциальных функций, МГУА, статистическими методами, допустимых преобразований, алгоритмами вычисления оценок (АВО) и др. В данной постановке нами выбран АВО, т.к. эти алгоритмы просты в реализации, достаточно универсальны, апробированы в решении ряда как фундаментальных, так и сугубо практических задач, а также в алгебраической постановке [1, 3] доказана их сходимость.

Распознающие модели были апробированы при решении, как тестовых задач, так и априорных задач моделирования и управления процессом флотационного обогащения.

Были рассмотрены два класса объектов, характеристики

функционирования которых сведены в таблицу T_{nmi} . В первом классе реализация 20 состояний объекта с «хорошим» ходом протекания процесса, во втором 20 состояний – с «плохим». В качестве параметров описания ОУ были выбраны x_1 - расход сернистого натрия, x_2 - тоже ксантогенета, x_3 - тоже вспенивателя, x_4 - содержание ценного компонента в питании, x_5 - щелочность пульпы, x_6 - производительность, x_7 - плотность пульпы в питании, x_8 - то же в хвосте основной флотации, x_9 - содержание ценного компонента в хвосте основной флотации, x_{10} - объемный расход пульпы в питании основной флотации. Здесь $y = f(x_i) = \beta_2$ - содержание ценного компонента, т.е. меди, в концентрате основной флотации. В этом случае таблица T_{nmi} имеет размерность 10×40 и $l=2$. для каждой реализации $\beta_2^i (i = \overline{1,40})$ имела свое конкретное значение. В классах объекты располагались по убыванию β_2^i . Один из объектов каждого класса выбирался случайным образом и предъявлялась к обучению таблица T_{nmi} , где $m=38$. Результатом применения распознающей модели с привлечением алгоритмов вычисления оценок явилось безусловное отнесение этих объектов к своему классу. Настройка же управляющих параметров x_1, x_2, x_3 и x_5 - позволила найти такие их значения, при которых объект из «плохой» ситуации переходит в класс «хорошей» реализации. Таким образом, можно отметить, что разработанный метод распознающей модели может служить достаточно удобным и адекватным орудием при исследовании и практической реализации задач моделирования, диагностики и управления сложными объектами различного назначения.

Литература

1. Журавлев Ю.И., Камиллов М.М., Туляганов Ш.Е. Алгоритмы вычисления оценок и их применение // ФАН, Ташкент, 1974, -119 с.
2. Алиев Э.М. Принципы многовариантного доминирования в оптимальном управлении технологическими процессами // Известия АН УзССР, вып.6, ФАН, Ташкент, 1987, С.6-10
3. Журавлев Ю.И. Об алгоритмическом подходе к решению задач распознавания или классификации // Проблемы кибернетики, 1978, вып.33, С.62-77.

Различение отражающих участков антенного полигона по измерениям суммарного поля в рабочей зоне

Д.Г. Асатрян, Г.М. Бабаян

(Ереван)

Введение

Задача испытания слабонаправленных антенн на больших антенных полигонах часто приводит к необходимости уменьшения или учета влияния паразитных отражений от поверхности полигона на точность определения характеристик антенн. Если не принимать специальных мер, то ошибки, связанные с паразитными отражениями, могут достигнуть весьма больших значений. При этом участки поверхности, существенные при отражениях, не только заранее неизвестны, но и меняются в зависимости от длины волны излучаемых волн, погодных условий и др. Поэтому разработка эффективных методов обнаружения и различения указанных участков при проведении точных антенных измерений является важной задачей для техники антенн.

В [1] предложена обобщенная математическая модель для описания системы "антенна-полигон" для антенн и полигонов произвольного типа, которая основана на геометрическом сложении полей, создаваемых прямой и отраженной волнами. Показана связь параметров модели с исходными параметрами системы. При этом параметры модели оцениваются по результатам измерения амплитудного распределения полей в рабочей зоне (в которой предполагается устанавливать испытываемую антенну). Вариации этого распределения содержат адекватную информацию о расположении и ориентации отражающих участков полигона, которая и извлекается путем надлежащей обработки данных. На основе же этой информации можно выбирать методику измерения и обработки данных, существенно снижающих влияние паразитных отражений на точность измерений.

Настоящая работа посвящена решению задачи различения отражающих участков поверхности антенного полигона при помощи предложенных в [1] точных и приближенных расчетных формул, а также численному моделированию и обработке данных.

2. Математическая модель

Для простоты рассмотрим ситуацию, когда полигон имеет только один участок, существенный при отражении. Для простоты мы будем также ограничиваться рассмотрением плоского случая и горизонтальной поляризации излучаемой волны.

Рис. 1 представляет вертикальное сечение пространства, в котором находится изучаемая система "антенна-полигон" и поясняет механизм взаимодействия прямой и отраженной от полигона волн в фиксированной точке плоскости, совмещенной с плоскостью воображаемого раскрытия испытываемой антенны. Здесь OO' - линия связи между точками A и B , причем в точке A расположен центр излучающей антенны, а в точке B - центр

воображаемого раскрыва испытываемой антенны, SS' - след отражающей плоскости, характеризуемый параметрами θ_0 и h_0 . Под отражающей плоскостью понимается плоскость, наилучшим образом (в среднеквадратическом смысле) аппроксимирующая данный участок поверхности полигона с центром S_0 . Тогда θ_0 - угол наклона отражающей плоскости относительно горизонта, а h_0 - расстояние от точки A до отражающей плоскости.

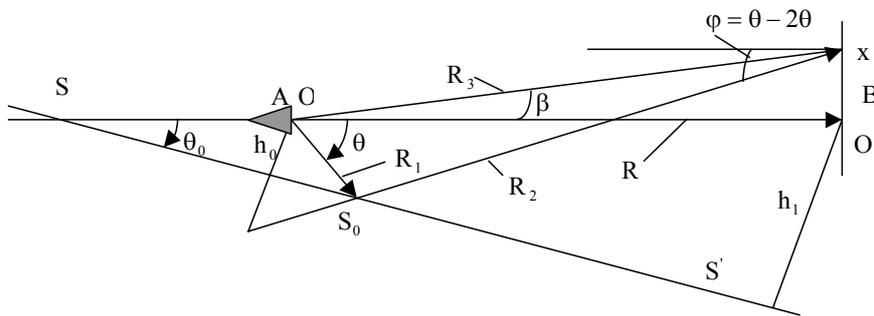


Рис. 1. Упрощенная геометрическая схема системы "антенна-полигон".

Согласно [1], необходимо проводить измерение амплитудного распределения суммы прямого (идущего по трассе R_3) и отраженного (идущего по трассе $R_1 + R_2$) волн на некотором участке плоскости, совмещенной с воображаемым раскрывом антенны. Точка x представляет собой текущую координату измерительной антенны и меняется в пределах $\pm x_{\max} / 2$.

В [1] показано, что при больших расстояниях R между антеннами по сравнению с $\max(\lambda, x)$, где λ - длина волны и при малых $\beta = x / R$ соответствующая интерференционная формула принимает следующий вид

$$|E|^2 \approx \alpha_0 + \alpha_1 \cos \alpha_3 \beta + \alpha_2 \sin \alpha_3 \beta, \quad (1)$$

где $\alpha_0 = |E_0|^2 (1 + G^2 S^2)$, $\alpha_1 = 2GS |E_0|^2 \cos kP$, $k = 2\pi / \lambda$,

$S = \left(1 + 4h_0 \sin \theta_0 / R + 4h_0^2 / R^2\right)^{-1/2}$, $\alpha_2 = -2GS |E_0|^2 \sin kP$,

$\alpha_3 = kQ$, $P = R(1/S - 1) + \Phi$, $Q = 2h_0 S \cos \theta_0$, $T = -QS^2 / R$,

$U = Q/R$, $V = (1 + 2h_0 \sin \theta_0 / R)^2 S^3$. Параметры G и Φ характеризуют отражающую способность данного участка полигона.

Модель (1) позволяет по измерениям, проведенным на полигоне в условиях мешающих отражений определить параметры как испытуемой антенны в свободном пространстве, так и полигона. Из приведенных формул следует, что вся необходимая информация о свойствах системы заключена в параметрах модели, связанных с исходными параметрами системы. Так например, можно показать, что $\sin \varphi \approx U + V\beta$, т.е. по величине отношения Q/R однозначно определяется угол φ падения отраженной волны в антенну B (при $\beta = 0$). Зная профиль полигона, можно выделить наиболее существенные при отражении участки его поверхности. Видно, что для этого сначала необходимо определить период α_3 осциллирующей составляющей измеренной зависимости $|E|^2$ от x .

Таким образом, решение задачи сводится к нахождению численных оценок параметров $\alpha_j, j = 0,1,2,3$ модели (1) по результатам дискретных измерений $|E|^2$ при различных значениях x .

3. Моделирование и численные результаты расчетов

Для оценивания неизвестных параметров (1) по экспериментальным данным использованы методы статистического нелинейного регрессионного анализа. При этом предполагается, что в точках x_1, x_2, \dots, x_n наблюдается случайная величина

$$Y = \alpha_0 + \alpha_1 \cos \alpha_3(x/R) + \alpha_2 \sin \alpha_3(x/R) + Z,$$

где Z - нормально распределенная случайная величина с нулевым средним и с неизвестной дисперсией. Требуется по результатам наблюдений оценить параметры $\alpha_j, j = 0,1,2,3$, проводив соответствующий статистический регрессионный анализ. Поскольку неизвестный параметр α_3 входит в модель нелинейно, то применяется метод наименьших квадратов в сочетании с процедурами последовательных приближений.

В докладе приводятся результаты численного моделирования с имитацией реального полигона с падающим рельефом и показывается эффективность предложенного метода при обнаружении отражающих участков поверхности антенного полигона.

Литература

1. Асатрян Д.Г. Математическая модель и обратные задачи системы "антенна-полигон". - Сб. трудов Всес. конф. "Антенные измерения"-ВКАИ-4. - Ереван: ВНИИРИ, 1987, с. 501-503.

Сжатие без потерь или с ограниченными потерями статических полутоновых изображений

В.Ф. Бабкин, И.М. Книжский, К.Е. Хрекин

(Москва)

Для задач исследования Земли и планет из космоса представляет интерес сжатие изображений без потерь (lossless) или с ограниченными потерями, не превышающими заданную величину (near lossless), что связано с необходимостью распознавания различных целевых объектов на поверхности и/или восстановления наблюдаемого физического процесса по результатам измерений (решение обратных задач). В силу этого широко распространённая методика сжатия изображений по стандарту JPEG [1] малоприменима для решения подобных задач, поскольку может внести неприемлемый уровень ошибок в задачу распознавания образов.

Предлагаемая нами схема сжатия полутоновых изображений без потерь и с ограниченными потерями, построена на основе адаптивного контекстного предсказателя (АКП) с полученным экспериментально набором весовых коэффициентов. Для работы АКП используется буфер на 2 строки исходного изображения, кроме того, такой же буфер (но уже на 2 строки ошибки предсказания) необходим для реализации адаптивного статистического кодера. Для энтропийного кодирования ошибки предсказания был использован разработанный нами адаптивный статистический кодер на основе кода Голомба [4], по эффективности в подобных задачах практически не уступающий (а иногда и превосходящий) даже наиболее удачные реализации арифметических кодеров, но значительно более быстрый. Результатом его использования явился заметный (более чем в 2 раза) рост скорости компрессии, что позволило без заметного замедления работы кодера путём некоторого усложнения схемы контекстного анализа дополнительно повысить эффективность адаптивного предсказателя. На рисунке 1 представлена блок-схема разработанного кодера.

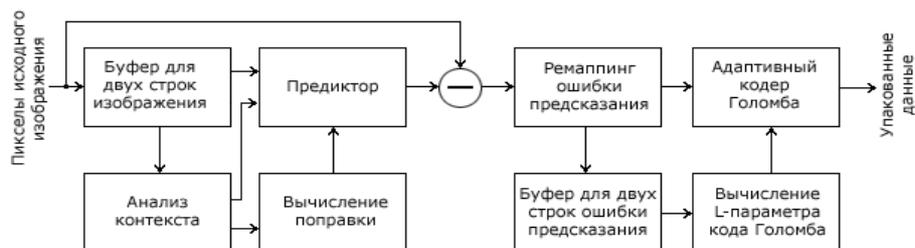


Рис.1 Блок-схема LLC-кодера.

Ниже (табл.1) приводятся сравнительные результаты эффективности предлагаемых решений на стандартных тестовых изображениях. Колонка LLC 0.5 соответствует разработанному нами кодеру. Относительно прочих

представленных кодеров следует сделать некоторые пояснения. Колонки CALIC'2002 и CALIC'1999 [3] соответствуют двум различным реализациям алгоритма. Кодер JPEG-LS [2] доступен в исходных текстах для некоммерческого использования (JPEG-LS IMPLEMENTATION V.2.1 (C) University of British Columbia). Для экспериментов с JPEG2000 использовалась условно бесплатная утилита LuraWave SmartCompress 3.0. В последней колонке приведены результаты работы архиватора WinRAR 3.0 (режим работы архиватора: compression method best, dictionary size 4096 KB).

Таблица 1.

	Размеры (WxH)	BMF 1.1 (-F-S)	LLC 0.5	CALIC 2002	CALIC 1999	JPEG -LS	JPEG 2000 lossless	WinRar 3.0
airfield.pgm	512x512	5.429	4.985	5.426	5.475	5.566	5.858	6.195
bridge.pgm	512x512	3.718	3.506	3.894	5.375	5.500	5.760	4.386
couple.pgm	512x512	4.471	4.232	4.554	4.596	4.677	4.863	5.368
harbour.pgm	512x512	4.299	4.452	4.363	4.458	4.494	4.797	5.219
lena.pgm	512x512	3.958	4.095	4.073	4.121	4.237	4.330	5.135
man.pgm	512x512	4.243	4.358	4.343	4.385	4.505	4.716	5.370
mandrill.pgm	512x512	5.753	5.906	5.889	5.899	6.038	6.130	6.633
peppers.pgm	512x512	4.037	4.198	4.182	4.209	4.289	4.436	5.456
sailboat.pgm	512x512	4.515	4.691	4.659	4.695	4.769	4.955	5.543
woman1.pgm	512x512	4.414	3.985	4.447	4.555	4.672	4.837	5.552
woman2.pgm	512x512	3.031	3.166	3.171	3.202	3.300	3.339	4.052
balloon.pgm	720x576	2.672	2.845	2.782	2.838	2.904	3.056	3.793
board.pgm	720x576	3.352	3.569	3.514	3.579	3.675	3.800	4.710
girl.pgm	720x576	3.539	3.795	3.731	3.788	3.925	4.083	4.996
gold.pgm	720x576	4.271	4.411	4.362	4.406	4.477	4.626	5.087
Среднее(bpp)	-	4.025	4.080	4.141	4.275	4.371	4.539	5.097

Наилучшие результаты на большинстве изображений продемонстрировал кодер BMF 1.1 (автор Д.Шкарин), правда, он же оказался одним из самых “неторопливых” (см. табл.2).

Результаты сжатия в режиме near lossless в таблице отсутствуют, поскольку, с одной стороны, не все представленные кодеры этот режим поддерживают, с другой – каждый из поддерживающих его в режиме *error=1* (ошибка при восстановлении по абсолютной величине не превышает 1) обеспечивает коэффициент сжатия в 1.5 раза больший, чем в режиме lossless, а в режиме *error=2* коэффициент сжатия увеличивается в 2 раза (также по сравнению с lossless).

В таблице 2 приведены результаты сжатия без потерь большого тестового изображения (аэрофотография): файл Frame147.pgm, размеры 3606x3914 пикселей, 8 бит на пиксел, и время, потребовавшееся кодеру для его упаковки (конфигурация тестового компьютера: CPU Intel Pentium 4, 2.0 ГГц, RAM 256 MB, операционная система – Windows 98SE):

Таблица 2

	JPEG-LS	LLC 0.5	WinRAR 3.0	CALIC 1999	CALIC 2002	BMF 1.1 (-F-S)	JPEG 2000
Bit rates, bpp:	3.239	3.103	3.882	3.129	3.067	2.919	3.281
Время работы, с:	2.2	5.0	10.5	10.7	11.6	16.8	129.5

Следует отметить, что непосредственное применение алгоритмов, подобных используемым JPEG-LS, CALIC или LLC для сжатия цветных (в общем случае - многокомпонентных) изображений, не вполне адекватно решаемой задаче, поскольку использование сжатия независимо внутри каждой цветовой (спектральной) плоскости как правило неспособно обеспечить коэффициент сжатия больший 2.5 – 3 в режиме lossless. Для дальнейшего повышения степени сжатия подобных изображений на первый взгляд достаточно привлекательным выглядит использование трёхмерных схем контекстного анализа, однако подобный подход неизбежно приводит к усложнению реализации. Так, например, число различных контекстов в двумерной схеме CALIC равно 576 (в LLC – до 1024, точное число зависит от граничных условий в схеме предиктора), а использование трёхмерной схемы увеличивает их количество ещё на порядок и размер контекстного буфера оказывается неприемлемым для практической реализации. Менее ресурсоёмким представляется использование для сжатия многокомпонентных изображений преобразований типа Уолша-Адамара вдоль оси частот в сочетании с контекстным анализом в плоскостях коэффициентов. Предварительные эксперименты продемонстрировали эффективность подобного подхода, во всяком случае – для трёхкомпонентных RGB-изображений.

Литература:

1. W.B.Pennebaker, J.L.Mitchell “JPEG still image data compression standard”, Van Nostrand Reinhold, 1992, ISBN 0-442-01272-1.
2. M.J.Weinberger, G.Seroussi, G.Sapiro, “LOCO-I: A low complexity lossless image compression algorithm.” ISO/IEC JTC1/SC29/WG1 document N203, July 1995.
3. X.Wu, N.Memon, “Context-Based, Adaptive, Lossless Image Coding”, IEEE Trans. On Communications, vol.45, No.4, pp.437-444
4. S.W.Golomb, “Run-length encodings”, IEEE Trans. Inform. Theory, vol.IT-12, pp.399-401, 1966.

Автоматизация палеографического исследования древних рукописей

Д.С. Баскаков, Л.М. Местецкий
(Тверь)

Введение

Средневековые рукописные книги являются величайшим культурным наследием, предметом постоянных исследований в современной исторической науке. Важную роль в этих исследованиях играет палеографический анализ текстов, задачи которого — идентификация почерков писцов, определение числа писцов, работавших над рукописью, идентификация разрозненных фрагментов древних книг. Традиционные методы палеографического анализа базируются на «ручной технике»: исследователь с помощью циркуля и линейки осуществляет обмеры элементов текста, а затем по этим измерениям осуществляет "на глаз" палеографическую идентификацию. Такая техника объективно не точна и при этом очень трудоемка. Процессы получения значимых результатов в палеографии малочисленными исследовательскими группами растягиваются на долгие годы, многие из древних рукописных книг оказываются вне поля зрения исследователей.

Работа посвящена исследованию возможности автоматизации палеографического анализа на основе использования компьютерных методов. Главной целью такой автоматизации является повышение эффективности работы исследователей древних рукописей за счет снижения трудозатрат на рутинную техническую часть работы, а также за счет повышения качества и надежности результатов палеографических исследований.

Подход к решению задачи

Материалом исследования служили почерки двух основных авторов Остромирова Евангелия (Рис. 1).



Рис. 1. Фрагменты текста Остромирова Евангелия (1056-1057гг.). Представлены почерки двух писцов.

Метод решения основывается на традиционном подходе палеографического исследования рукописей, который заключается в сравнительном анализе начертаний одних и тех же букв в разных местах

древних документов.

Предлагаемый подход включает в себя следующие этапы:

1. предобработка изображения: выделение символов, фильтрация дефектов;
2. получение гранично-скелетного представления текста и признакового описания символов на его основе (Рис. 2). Гранично-скелетное представление включает аппроксимацию исходного растрового образа полигональной областью и непрерывный скелет (множество серединных осей области) [1];
3. классификация символов по алфавиту в тексте рукописи;
4. отбор из всего множества распознанных символов элементов с наибольшей достоверностью классификации (выбор так называемых «ярких представителей» классов);
5. построение признаковой модели, характеризующей особенности почерка (генерация признаков посимвольного анализа и общих геометрических признаков почерка).

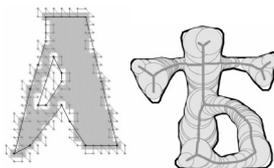


Рис. 2. Контур и скелет символов

Распознавание символов

Распознавание символов включает: построение базы прецедентов, генерацию признаков, построение и оценку классификатора.

База прецедентов строится на основе экспертной классификации локализованных символов рукописи по алфавиту.

В качестве признакового описания символов предлагается использовать 8 геометрических признаков, получаемых из контурного представления букв: отношение ширины буквы к высоте, периметр контура, площадь символа, две координаты центра тяжести, округлость, число «дыр» и их площадь. Все величины приводятся к размерам ограничивающей рамки символа.

В качестве алгоритма классификации используется модель многослойного персептрона, осуществляющая распознавание символов на основе вектора признаков. Достигнутая в ходе обучения нейронной сети точность распознавания символов составляет 92% на контрольной выборке.

Дальнейший сравнительный анализ почерков осуществляется для символов, изображающих одну и ту же букву алфавита. При этом для анализа выбираются те символы, у которых высока достоверность классификации, так называемые «яркие представители».

Выявление особенностей почерка

Задачей данного этапа является разработка признакового описания почерка. Для этого предлагается анализировать почерк с помощью двух видов показателей: величинами, характеризующими начертание отдельных букв (ярких представителей классов), и некоторыми общими геометрическими свойствами почерка.

В качестве инструмента сравнения письма отдельных символов используется признаковая модель начертания букв. Она включает признаки, описывающие извилистость контура: вариацию касательной и число вершин многоугольной фигуры. Первый из них вычисляется как вариация угла между последовательными ребрами многоугольной фигуры. Число вершин определяется непосредственно из гранично-скелетного представления символа. Чем более извилиста граница символа, тем выше должны быть значения этих признаков.

Для анализа геометрических характеристик почерка используются следующие признаки: ширина штриха почерка (Рис.3), размеры букв, величина пробелов в строках. Эти показатели рассчитываются по всем символам представленного фрагмента текста.

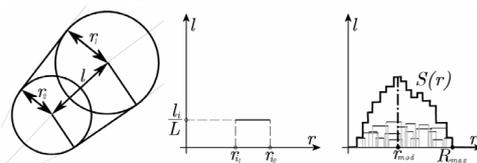


Рис. 3. Вычисление ширины штриха (элемент штриха, функция распределения ширины одного элемента, суммарная функция распределения ширины)

Результатом применения итоговой признаковой модели почерка к фрагменту рукописи является набор показателей двух видов: характеристик начертания каждого типа букв (посимвольный анализ), общих геометрических свойств почерка. На основе этих значений осуществляется сравнительный анализ нескольких фрагментов текста.

Заключение

Полученные результаты показывают, что применение компьютерных методов для палеографического анализа является вполне обоснованным. Во-первых, существуют возможности вычисления информативных классификационных признаков на основе обработки бинарного изображения текста. Во-вторых, высокая скорость обработки изображения обеспечивает существенное снижение общего времени выполнения рутинных операций необходимых исследователю-палеографу.

Литература

1. Местецкий Л.М. Непрерывный скелет бинарного растрового изображения // Графикон-98, -М.: МГУ, 1998.

Статистическая оценка цветовых компонент губ и лица для вычисления контуров рта с использованием деформируемых шаблонов

А.В. Бовырин, К.В. Родюшкин
(Нижний Новгород)

Описание основного алгоритма и его недостатки

Для оценки контуров губ представляет интерес метод деформируемых шаблонов [0,0]. Данный метод основан на минимизации некоторой целевой функции по параметрам определяющим геометрическую форму модели губ. Этот метод получил широкое распространение благодаря тому, что деформируемые модели обладают большой гибкостью и в тоже время позволяют ввести жесткие ограничения на их допустимые формы. Также данный метод привлекателен тем, что позволяет при оценке формы модели совместно использовать множество различных признаков. Например, в [0] данными признаками являются: само изображение, карты перепадов, карта «холмов и провалов», в [0] предлагается при слежении за ртом и глазами использовать информацию о текстуре, взятую с предыдущего и первого кадров. В работах [0,0] в качестве исходных данных используется серое (не цветное) изображение, в этом случае достаточно хорошо производится оценка границ верхней губы, поскольку эти границы хорошо выражены на сером изображении. Однако использование только яркостной компоненты затруднительно для правильной оценки кривой описывающей нижнюю границу нижней губы из-за возникающих теней в этой области (рис. 1а). Более того, во многих случаях данная граница на сером изображении отсутствует.

Использование оценки цветовых компонент губ и лица

Во многих работах предложено использовать цветовые компоненты для оценки формы рта [0]. Однако цветовая компонента обычно является достаточно зашумленной, поэтому получаемые оценки контуров на основе только цветовой информации, являются ненадежными. В данной работе предлагается модифицировать предложенный в [0,0] метод путем статистической оценки цветовых компонент губ и кожи лица и использовании полученных данных в качестве дополнительных признаков при оценке контура рта методом деформируемых шаблонов. Для этого производится первоначальная оценка контура губ без использования цветовой компоненты (рис. 1а). Затем, используя полученные границы верхней губы, производится оценка цветовых компонент губ и кожи лица (рис. 2б). По полученным данным строится карта губ и лица $M_c(x, y)$ (рис. 2в) и вычисляется коэффициент L , определяющий степень различия в цвете между губами и кожей лица. Элемент карты $M_c(x, y)$ принимает значение

1, если пиксель с координатами (x, y) имеет цвет губы и значение -1 , если он имеет цвет кожи лица и промежуточные значения при неопределенном цвете. После этого производится новая оценка границ рта (рис. 1б). При этом к основной целевой функции, используемой в обычном методе деформируемых шаблонов, добавляется слагаемое $-L * E_c(\mathbf{p}, M_c)$, где $E_c(\mathbf{p}, M_c)$ – интеграл по области нижней губы от карты губ $M_c(x, y)$, \mathbf{p} – вектор параметров, определяющий форму губ.

Статистическая оценка цветовых компонент губ и лица

В результате первоначальной оценки контура губ (без использования цветовой компоненты) получается обучающее множество состоящее из точек класса “губы” и класса “лицо” (рис. 2а). Предполагается, что исходное изображение представлено в YCrCb пространстве и статистическая оценка производится в плоскости CrCb. Для этого строятся двухмерные гистограммы (Cr, Cb) – точек обучающего множества отдельно для каждого класса. Если принять, что априорная вероятность принадлежности классу одинаковая, то поскольку в обучающем множестве может присутствовать разное количество точек губ и лица, полученные гистограммы выравниваются по объёму. Далее для каждой точки из пространства CrCb $(Cr, Cb \in [0, 255])$ оценивается вероятность её принадлежности классу “губы” $P_g(Cr, Cb)$ и классу “лицо” $P_l(Cr, Cb)$ ($P_g(Cr, Cb) + P_l(Cr, Cb) = 1$) (рис. 2б). Для вычисления этих оценок применяется метод kNN (k -nearest neighbor) [4], который не требует каких-либо априорных знаний о модели распределения классов и заключается в нахождении k ближайших точек обучающего множества. Используя полученные вероятности, вычисляется введенная выше карта губ и лица $M_c(x, y)$ (рис 2в) и коэффициент L .

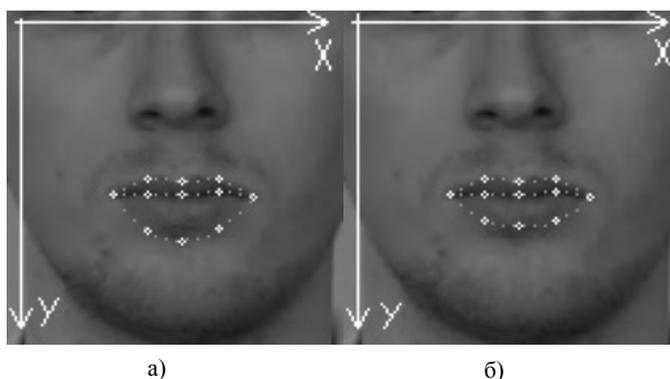


Рис. 1. Оценка контуров губ. а – первичная, без использования цветových компонент, б – дополнительная с использованием цветových компонент исходного изображения

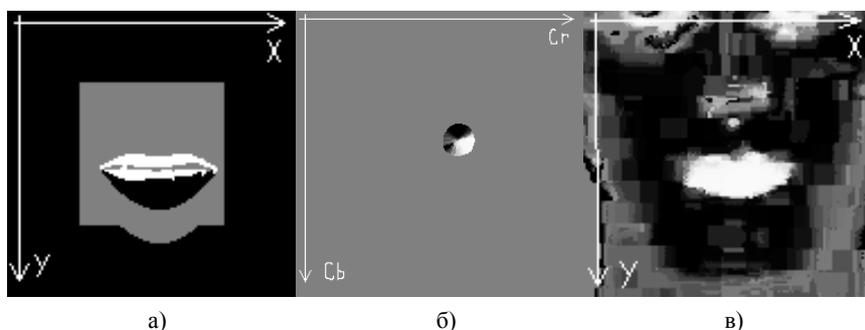


Рис. 2. Статистическая оценка карты губ лица. а) – классификация пикселей, белый – «губы», серый – «лицо». б) – вероятность принадлежности к классу «губы». в) – карта губ и лица.

Литература

Yuille, A. L., Hallinan, P. W. and Cohen, D. S. (1992) Feature extraction from faces using deformable templates. *International Journal of Computer Vision* 8 (2): pp 99-111.

M. Malciu, F. Prêteux, “Tracking facial features in video sequences using a deformable model-based approach” *Proceedings SPIE Conf. on Mathematical Modeling, Estimation and Imaging*, San Diego, CA, vol. 4121, pp. 51-62, 2000.

M U Ramos S´anchez, J Matas and J Kittler, “Statistical chromaticity models for lip tracking with B-splines.” *Proceedings Int. Conf. On Audio- and Video-based Biometric Person Authentication*, Crans Montana, Switzerland, 1997.

Cover, T. M. and Hart, P. E. Nearest Neighbor Pattern Classification. *IEEE Transactions on Information Theory*, IT-13(1):21–27, 1967.

Применение вейвлет-анализа сигнала в системе распознавания речи

Ф.Г. Бойков, Т.К. Старожилова
(Москва)

Введение

В данной работе описана серия экспериментов по применению вейвлет анализа для задач распознавания речи. Получены оценки точности распознавания изолированных слов и слитно произносимых последовательностей цифр при использовании блока предобработки, основанного на вейвлет-преобразовании речевого сигнала. Применение вейвлетов в задачах обработки и распознавания речи продиктовано особенностями речевого акустического сигнала. Вейвлеты, как средство многомасштабного анализа позволяют выделять, одновременно как

основные характеристики сигнала, так и короткоживущие высокочастотные явления в речевом сигнале. Это свойство является существенным преимуществом в задачах обработки речевого сигнала по сравнению с оконным преобразованием Фурье, где, варьируя ширину окна, приходится выбирать масштаб явлений, которые необходимо выделить в сигнале.

Применение вейвлет-анализа

Вейвлет-анализ – это исследование сигнала $f(t)$ при помощи разложения по системе базисных функций. Сигнал $f(t)$ интерпретируется, как функция из $L^2(\mathbf{R})$, а в качестве базиса используется система функций

$$\psi_{a,b}(t) = \psi\left(\frac{b-t}{a}\right),$$

занумерованных не целыми числами, а двумя непрерывными параметрами. Эта система получается из фиксированной функции $\psi(t)$ всевозможными сдвигами и растяжениями. Функция $\psi(t)$ называется вейвлетом (по-английски – wavelet; в русской математической литературе используется также термин «всплеск»), если: $\psi(t)$ непрерывна; $\psi(t)$ интегрируема на всей прямой, интеграл от $\psi(t)$ по всей оси t равен нулю..

Вейвлет-преобразованием $f(t)$ называется функция двух переменных

$$Wf(b,a) = \frac{1}{a} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{b-t}{a}\right) dt$$

На каждом частотном уровне количество центров частотно-временной локализации в два раза меньше, чем на предыдущем уровне, частота которого выше. Существует корреляция между вейвлет коэффициентами, как по шкале времени, так и по шкале частот.

Численные эксперименты по распознаванию речи

Нами был разработан блок предобработки речи на основе вейвлетов. В качестве вейвлет-базиса был использован базис Добеши-9. Поскольку этот базис является ортонормированным, то это дало возможность реализовать быстрый алгоритм вычисления вейвлет-коэффициентов на каждом частотном уровне через уже найденные коэффициенты на уровне с более высокой частотой.

Блок предобработки, который оценивает информативные параметры речевого сигнала на основе вейвлет-коэффициентов был интегрирован в систему распознавания речи ВЦ РАН [2] вместо блока вычисления мел-

кепстральных параметров. Система распознавания речи основана на моделировании речевого сигнала с помощью дискретных марковских моделей аллофонов (контекстно-зависимых вариантов фонем). В описанных экспериментах система распознавания включала модели для алфавита из 540 марковских моделей аллофонов, полученных с помощью построения бинарного решающего дерева. Распознавание речевого сигнала выполнялось с помощью процедуры Витерби. Эксперименты по распознаванию проводились на материале фонетической части речевого корпуса данных TeCoRus. Применяя оконное вейвлет-преобразование, варьировалось количество частотных уровней вейвлет-коэффициентов. При заданной верхней частоте вейвлет-коэффициентов количество частотных уровней, ширина окна и количество используемых вейвлет-коэффициентов однозначно определяются нижним уровнем частот коэффициентов.

Использование слишком низкого порога нижней частоты приводит к излишнему усложнению вычислительных операций, а ограничение преобразования более высоким порогом нижних частот приводит к потерям необходимой информации для распознавания речи. С целью оптимизировать нижний уровень частот вейвлет-преобразования были проведены испытания системы для различного уровня нижних частот: 400 Гц, 800 Гц и 1600 Гц.

В таблице 1 приведены параметры вейвлет преобразования для используемых частот и полученная точность распознавания.

Таблица 1. Параметры вейвлет преобразования и полученная оценка ошибки распознавания.

Нижняя частота, (Гц)	Размер “окна” (точки)	Количество параметров	Ошибка распознавания
400	960	25	22,6%
800	480	13	9,1%
1600	240	7	19,1%

В следующем эксперименте производились оценки точности для изолированного произношения и слитного произношения цифр. В таблице 2 представлены результаты тестирования системы для слитного и изолированного произношения (ошибка указана в целом и для каждого пола отдельно).

Таблица 2. Ошибка распознавания в процентах для изолированного и слитного произношения.

Тип произношения	Мужчины	Женщины	Всего
Изолированное произношение	12%	8%	10%
Слитное произношение	32%	36%	34%
Всего	22%	22%	22%

С целью повысить точность распознавания было принято решение проводить обучение системы отдельно для разных полов. В таблице 3

представлена ошибка распознавания для разных полов, на моделях, построенных для каждого пола дикторов отдельно.

Таблица 3. Ошибка распознавания в процентах для изолированного и слитного произношения. Обучение велось для каждого пола отдельно.

Тип произношения	Мужчины	Женщины
Изолированное произношение	6%	6%
Слитное произношение	28%	36%
Всего	17%	21%

Представленные результаты уступают результатам, которые получены на основе кепстральных параметров, однако, в данном случае эксперименты носили предварительный характер. В частности, не проводилась работа по оптимизации признаков, полученных на основе вейвлетов. В настоящий момент в этих направлениях проводятся исследования. Предварительные результаты, описанные в этой статье, дают основания полагать, что после проведения оптимизации точность распознавания будет существенно улучшена, и превысит точность системы распознавания на основе кепстральных параметров. Полученные в данной работе предварительные результаты дают основания полагать, что вейвлет-анализ речевого сигнала может быть использован для построения систем распознавания изолированной и слитной речи.

Литература

1. Daubechies. Ten Lectures on Wavelets. //Number 61 in CBMS-NSF Series in Applied Mathematics. SIAM Publications, Philadelphia, 1992.
2. Чучупал В.Я., Маковкин К.А., Чичагов А.В. К вопросу об оптимальном выборе алфавита моделей звуков русской речи для распознавания речи //Искусственный интеллект, том 4, №1, 2002, стр.575-579, Наука і освіта, Киев.

Методы и подходы к решению обратной задачи акустической термотографии при наличии шума

М.С. Босняков
(Москва)

Введение

Регистрация собственного теплового акустического излучения позволяет получить информацию о распределении внутренней температуры биологических объектов неинвазивным способом [1]. Знание распределения глубинной температуры исключительно важно как для диагностики различных заболеваний, так и для мониторинга процесса лечения. Например, при лечении онкологических больных методом гипертермии опухоль необходимо нагреть и поддерживать ее температуру около 42° С с

точностью ≈ 0.3 К, не нагревая остальные ткани. Для этих целей ранее был предложен метод акустотермотомографии (см. например [1,2]). В его основе лежит тот факт, что для измерения глубинной температуры можно использовать информацию, которую несет тепловое акустическое излучение. Пьезопреобразователем измеряется некоторая интегральная температура вдоль оси диаграммы направленности.

$$\int \gamma(l) u(l) \exp\left(-\int_0^l \gamma(\xi) d\xi\right) dl = b \quad (1)$$

где l -направление сканирования $\gamma(l)$, $u(l)$ - распределения коэффициента поглощения и температуры вдоль l соответственно. Для измерения пространственного распределения температуры необходимо провести серию подобных измерений в разных направлениях, и по ним восстановить искомое распределение. Таким образом, задача акустотермотомографии сводится (см. [2]) к решению задачи

$$Au = b \quad (2)$$

где A – оператор, вычисленный для разных углов сканирования тела. Уравнение (2) является некорректно поставленной задачей и для её решения необходимо использовать методы регуляризации.

Методы и подходы

Для решения некорректных задач разработано множество методов регуляризации и подходов (см. например [2,3]). Эти методы основаны на поиске решения в различных пространствах L_2 , C и т.д. Каждый из методов имеет свои границы применения в зависимости от исследуемой задачи. Однако, все методы решения практически не применимы при наличии большого аддитивного шума. В задаче акустической термотомографии наличие большого аддитивного шума объясняется тем, что температура сканирующего датчика равна температуре тела. Таким образом, возникает задача эффективного устранения шума без «повреждения» исходного сигнала. Такая возможность появилась с последними достижениями в области вейвлет анализа. В работе [4] был предложен и математически обоснован метод wavelet de-noising. В этом методе используется так называемый кратномасштабный вейвлет анализ [5]. Одним из свойств, кратномасштабного вейвлет анализа является возможность подобрать оптимальный в некотором смысле базис, в котором сигнал представляется наименьшим числом коэффициентов. В этом случае энергия шума, попадающая в спектр сигнала минимальна. Зануляя пороговой функцией только неинформативные коэффициенты разложения, можно достичь оптимального в некотором смысле устранения шума. В работе [6] были исследованы возможности построения оптимального вейвлет базиса для

сигнала, получаемого в задаче акустической томографии. Был проведен численный эксперимент по восстановлению зашумленного модельного сигнала (см. Рис.1). Модельное соотношение сигнал шум $SNR=2.5-3$. Точность восстановления в пике 5%-9%.

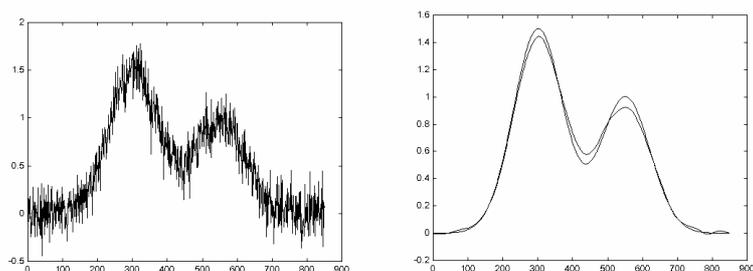


Рис.1 Зашумленный модельный сигнал (слева) и сигнал после операции de-noising(справа)

Следует отметить, что метод de-noising применим к сигналу, полученному только лишь с помощью «последовательной» схемы сканирования, в которой угол сканирования для всех датчиков является одинаковым и равен константе. При такой схеме сканирования измеряемый сигнал является проекцией искомой функции распределения. Априори известно, что искомая функция распределения удовлетворяет уравнению теплопроводности и, следовательно, дважды непрерывно дифференцируема. Очевидным образом можно показать, что сигнал-проекция обладает теми же самыми свойствами, что существенно облегчает применение метода de-noising. Следует отметить, что использование «последовательной» схемы сканирования отрицательно сказывается на обусловленности томографической матрицы A , что делает уравнение (2) необратимым практически для всех методов регуляризации.

В данном свете представляется актуальным исследование экспоненциального оператора Радона [7], который подразумевает под собой совокупность «последовательных» схем сканирования для различных углов поворота линейки датчиков вокруг исследуемого объекта. Следует отметить, что оператор Радона обратим с помощью теоремы о проекции в Фурье пространстве. Особое внимание следует уделить случаю, когда угол поворота линейки датчиков изменяется от 0° до 180° , что соответствует схеме сканирования используемой в маммографии.

Работа поддержана РФФИ. Проект № 03-01-00-723.

Литература

1. Гуляев Ю.В., Бограчев К.М., Боровиков И.П., Обухов Ю.В., Пасечник В.И. Пассивная термоакустическая томография - методы и подходы. // Радиотехника и электроника 1998 Т.43 №9 с.140-146

2. Аносов А.А., Пасечник В.И. Пространственная обратная задача акустотермографии //Акуст. журн. 1994. Т.40. №6. с.885-889
3. Bosnyakov M.S., Obukhov Yu.V On Signal Reconstruction in the Uniform Norm Taking into Account a priori Information in the Form of Differential Equations Describing Signal Forming // Pattern Recognition and Image Analysis, Vol. 12, No. 1, 2002, pp. 57–62.
4. Donoho D.L. De-noising by soft-thresholding, IEEE Trans. on Inform. Theory, 41(3):613-627, 1995
5. Добеши И. Десять лекций по вейвлетам. Перевод с английского Е.В. Мищенко под редакцией А.П. Петухова.,Москва, Ижевск, 2001
6. Босняков М.С., Обухов Ю.В. Оптимальный вейвлет базис для представления функций удовлетворяющих уравнению теплопроводности. // труды конференции РОАИ-6-2002, Том 1, с. 80-84
7. Tretiak O., Metz C. The exponential Radon transform. // SIAM J. Appl. Math. 39, 1980

**Метод поиска признаков пространственно-временных
связей функционирования участков головного мозга
человека в задаче пассивного радиотеплового
картирования.**

Д.Ю. Боснякова, Ю.В. Гуляев, Ю.В. Обухов
(Москва)

Введение

Одним из перспективных подходов к созданию новых методов неинвазивной медицинской диагностики является развиваемый в Институте радиотехники и электроники РАН метод пассивной функциональной томографии [1]. Суть этого метода заключается в измерении собственных физических полей человека, генерируемых им в процессе жизнедеятельности, и их динамики во время проведения различных тестов-физиологических, физических, фармакологических и др. При этом измеряются временные серии изображений полей и излучений, анализ которых дает информацию о функционировании органов и тканей. Такой анализ имеет цель установить пространственно-временные связи во временной серии изображений, отличающие здоровых людей от больных.

В настоящей работе описаны методы обработки и анализа сигналов многоканальной радиотермографии мозга человека. Они направлены на выявление пространственно-временных взаимосвязей в функционировании мозга человека в процессе выполнения некоторых нагрузок.

Разработана технология обработки и анализа таких сигналов, основанная на выделении доминирующих процессов с помощью вейвлет анализа сигналов.

Метод динамического функционального картирования

Метод радиояркостного термокартирования - неинвазивный, ненагруженный для пациента метод, основанный на измерении собственного теплового СВЧ излучения мозга с помощью 12 антенн - аппликаторов, размещённых на голове испытуемого. Метод динамического функционального картирования заключается в том, что исследуются не абсолютные значения температур, а их изменения относительно значений в выбранный момент времени под воздействием функциональной пробы.

При разработке технологий обработки и анализа экспериментальных данных в работе использовались программные системы STATISTICA и MATLAB. Экспериментальные данные были систематизированы, и в рамках указанных пакетов были написаны специальные программы для решения различных задач анализа временных сигналов и их пространственных связей.

Вейвлет-денойзинг

Поскольку соотношение сигнал/шум радиотермографа достаточно мал, основная задача, возникающая на начальной стадии обработки - это устранение шума. Одним из основных критериев в обработке таких сигналов является устранение шума без "повреждения" исходного сигнала. В работе [2] был предложен и математически обоснован метод вейвлет-денойзинга. Суть метода заключается в том, что зашумленный сигнал разлагается по базису из двух функций - отвечающих за низкочастотную и высокочастотную компоненты сигнала соответственно. При этом полезный сигнал в таком базисе описывается меньшим числом коэффициентов разложения, и, следовательно, больший участок в спектре разложения можно считать шумом и занулить его пороговой функцией.

Частотно-временной анализ сигналов радиотермографии

Для выявления доминирующих процессов в сигналах многоканального радиотермографического обследования мозга был проведен вейвлет - анализ сигналов с материнской функцией Морле. Анализ трехмерных частотно-временных изображений сигналов показал, что температурные колебания головного мозга сосредоточены в определенном диапазоне частот 0,02-0,1 Гц. При этом доминирующими частотами являются частоты 0.05-0.07 Гц для различных испытуемых [4]. Затем были выбраны те частоты, которые вносят наибольший вклад в сигнал. Срез вейвлет - изображения на этой частоте мы принимаем за доминирующий процесс. Затем все 12 таких кривых одного пациента помещались на один график. Обнаруженно кратковременное совпадение пиков нескольких срезов вейвлет изображений на доминирующей частоте, которое свидетельствует о некоторой синхронизации функционирования разных участков мозга в эти интервалы времени. Анализ таких графиков для всех пациентов показал, что почти у каждого человека на протяжении всего эксперимента встречается, как

правило, 3-5 интервалов времени, в которых наблюдаются совпадение нескольких пиков срезов вейвлет изображений.

Технология обработки сигналов радиотермографа для корреляционного анализа

Ранее нами была показана возможность различения группы здоровых от групп больных с помощью корреляционной обработки полученных термокарт мозга нейрохирургических больных с данными клинического и инструментальных исследований [3]. Корреляционные матрицы сильно зависят от предобработки сигналов. Поэтому очень важно найти такие процедуры предобработки сигналов, которые давали бы наилучший результат для последующего корреляционного анализа.

В результате проведенного анализа [4] выявлено, что именно тренд вносит наибольший вклад в корреляцию между кривыми, увеличивая для некоторых пар каналов коэффициент корреляции, и уменьшая или не изменяя для других. Поэтому для устранения влияния трендовой, а также шумовой составляющей сигнала на корреляцию кривых, необходимо перед тем, как вычислять коэффициент корреляции выполнить вейвлет-денойзинг, убрать тренд с помощью низкочастотного фильтра и вычистить краевые эффекты.

Корреляционный анализ сигналов радиотермографа

По описанной технологии были построены корреляционные матрицы всех 12 каналов пятнадцати ликвидаторов ЧАЭС и семи здоровых людей для анализа функциональных связей участков головного мозга при устном счете. У всех испытуемых датчики устанавливались на одних и тех же участках головы. Почти у каждого обследуемого (как здорового, так и больного) выделяются три участка около диагонали корреляционной матрицы, это - датчики 1,2,3,4; датчики 5,6,7,8; и последняя четверка датчиков- 9,10, 11,12, на которых попарные коэффициенты корреляции внутри каждой из четверок существенно выше, чем коэффициенты корреляции в остальных участках матрицы. У больных гораздо чаще, чем у здоровых обследуемых, встречается отсутствие корреляции (или незначимый коэффициент корреляции) между некоторыми из каналов внутри одной из четверок. В результате анализа выявлено, что эти группы в корреляционной матрице отличаются за счет дрейфа во времени характеристик приемников. Отсутствие у большинства больных испытуемых приборной корреляции сигналов в некоторых из перечисленных каналов свидетельствует о том, что на приборную корреляцию накладываются нескоррелированные физиологические сигналы, что приводит к уменьшению коэффициентов корреляции, и является отличием больных обследуемых от здоровых. Таким образом, обследования показали, что функционирование мозга больных характеризуются большим числом нескоррелированных процессов.

Работа поддержана проектами РФФИ, №№ 02-01-00814, 03-01-06103.

Литература

1. Годик Э.Э., Гуляев Ю.В.. Динамическое картирование физических полей биологических объектов // Вестник АН СССР. Сер.физ., 1990, №1, с.78-87
2. Donoho D.L., Johnstone I.M. Adapting to Unknown Smoothness via Wavelet Shrinkage // Technical Report, Dep. Statistics, Stanford University, 1994
3. Obukhova D. Yu., Obukhov Yu. V., Sel'skii A.G. Statistical Analysis of Space and Time Dependencies in the Noninvasive Functional Medical Diagnostics // Pattern Recognition and Image Analysis, 2001, Vol. 11, No.2, pp. 358-360
4. Obukhova D. Yu., Obukhov Yu. V. The Technology of Wavelet Processing and Correlation Analysis of Multichannel Microwave Radiothermography // Pattern Recognition and Image Analysis, Vol. 13, No. 2, 2003, pp. 322–325.

Синтез социально-экономических моделей идентификации интерактивных систем программного управления

С.П. Ботуз
(Москва)

Задачи синтеза и проектирования интерактивных (диалоговых) систем программного управления социально-экономическими системами и сопровождения соответствующих нормативно-правовых актов охраны субъектов и объектов интеллектуальной собственности включают различные сферы не только интегрированных систем автоматизации проектирования (САПР) различного рода автоматизированных систем управления (АСУ, АСУП, АСУ ТП и т.п.), но и непосредственно основные процессы взаимодействия субъектов и объектов промышленной собственности (ОПС: изобретений, полезных моделей, промышленных образцов), которые возникают на различных стадиях проектирования и экспертизы состояния различных распределенных в открытом сетевом пространстве Интернет/Интранет информационных процессов.

Основная научная и практическая значимость настоящей работы состоит в том, что в ней рассматриваются постановки основных задач для синтеза социально-экономических моделей, нацеленных на решение проблемы автоматизации процессов проектирования и экспертизы состояния технически оптимальных интерактивных позиционных систем программного управления на основе развития теории и практики графо-аналитического исчисления, позволяющие придать процессу принятия решения визуальные формы, адаптированные на конкретное лицо, принимающее решение в заданной предметной области. При этом синтез социально-экономических моделей для решения вышеперечисленных задач предлагается осуществить с единой теоретической и методической позиции,

а именно, с позиции конструктивного развития и применения основных положений принципа минимальной (ограниченной) сложности в интегрированных САПР.

В докладе осуществлена квалификация и систематизация основного перечня нормативно-правовых документов и его тезауруса, приблизив его к понятию нормативно-правовых актов (НПА), так как эта формулировка при проектировании, экспертизе и регулировании социально-экономических систем конкретизирует существующее в настоящее время многообразие форм нормативно-правовых документов и наиболее близка общепринятой терминологии в области правовой охраны объектов интеллектуальной собственности.

В результате показано, что применение разработанных в [1-4] графо-аналитических парадигм в процессе проектирования и экспертизы НПА позволяет выявить не только все основные логические связи НПА с законами и подзаконными актами, включая их предметную привязку к сфере социально-правового сопровождения и охраны ОПС, но и придать этим связям визуальные графо-аналитические формы обобщенных вычислительных таблиц, на базе которых можно синтезировать эффективные системы интерактивного взаимодействия экспертов в сети, контролировать, идентифицировать и классифицировать большие экспертные группы в процессе проектирования и согласования сложных НПА, которые, как правило, затрагивают многие предметные области и социальные группы населения.

Результаты настоящей работы, относящиеся к области проектирования и экспертизы систем интерактивного программного управления могут быть использованы при подготовке специалистов для экспертизы ОПС в учебных процессах подготовки и специализации студентов, педагогов и специалистов в области экспертизы состояния ОПС в различных предметных сферах, а также: в процессе проектирования систем научной экспертизы не только социально-экономических систем, различных законопроектов, но и любых других нормативно-правовых актов в заданной предметной области; при проектировании систем социально-экономического моделирования взаимодействия субъектов и объектов интеллектуальной собственности в открытом сетевом пространстве Интернет; при анализе и синтезе логических структур и моделей социально-экономического взаимодействия субъектов и объектов интеллектуальной собственности; в процессе комплексной экспертизы нормативно-правовых актов и т.п.

Литература

1. Ботуз С.П. Графо-аналитический метод визуализации состояния распределенных вычислительных процессов и систем управления / Труды международной конференции "Параллельные вычисления и задачи управления" (РАСО'2001). Ч.4. Математические модели,

- технологии и языки параллельных вычислительных процессов. – М.: ИПУ РАН, 2001.
2. Ботуз С.П. Автоматизированный синтез методов графо-аналитической декомпозиции моделей нелинейных систем программного управления. В кн.: Декомпозиционные методы в математическом моделировании / Под общей ред. член-корр. РАН Ю.Н. Павловского. – М.: ВЦ РАН, 2001.
 3. Ботуз С.П. Модели эволюции информационных технологий средств промышленной автоматизации. – М.: ИПРЖ "Радиотехника", 1998.
 4. Ботуз С.П. Методы проектирования и экспертизы технически оптимальных позиционных систем программного управления. Автореф. дис. докт. техн. наук. – М.: МИЭМ, 2003.

**Методы идентификации и классификации процессов
взаимодействия субъектов и объектов интеллектуальной
собственности**

С.П. Ботуз, А.В. Кулемин, С.П. Лукницкий
(Москва)

Центральной и наиболее актуальной проблемой в организации любого процесса управления в интегрированных системах автоматизации проектирования (ИСАПР) систем идентификации и классификации в любой предметной области является обеспечение субъектов интеллектуальной собственности (или лиц, принимающих решение ЛПР) полными, своевременными и достоверными данными. В то же время проектирование систем программного управления процессами взаимодействия субъектов и объектов интеллектуальной собственности (ОИС), например, процессов принятия решений или экспертизы объектов промышленной собственности: изобретений, полезных моделей, промышленных образцов в САПР, необходимо рассматривать с точки зрения научной дисциплины, изучающей все стороны (социальные, психологические, логические, информационные и математические) принятия решений. В дополнение следует отметить, что процесс проектирования и экспертизы состояния нормативно-правовых актов (НПА) представляет сложный существенно нелинейный социально-экономический процесс, который характеризуется множеством, как правило, распределенных во времени и пространстве факторов или параметров (например, этот процесс обладает социальной направленностью и целями того или иного НПА, закона и т.п., его структурой, соотношением норм различного типа: разрешительными, обязательными, запретительными). При этом оценка и влияние каждого из вышеперечисленных факторов на практике предопределены той позицией или точкой зрения, которую занимал (или занимает) ЛПР (проектировщик) того или иного НПА в

интегрированных системах автоматизации проектирования.

В этой связи в докладе рассматривается применение проблемно-адаптивного подхода, методов генерации проблемно-ориентированной среды проектирования и программно-аппаратных средств в различных предметных областях для синтеза соответствующих специализированных логических схем автоматов, придающих процедурам принятия решений не только систематизированный вид, но и, пожалуй самое главное, позволяющие сформировать или синтезировать в условиях неопределенности информации некоторую упорядоченную вычислительную среду (ВС) проектирования минимальной (ограниченной или, более точно, персонифицированной) сложности.

В докладе рассмотрены теоретические, методические и алгоритмические средства проектирования диалоговых (интерактивных) сред взаимодействия ЛПП-ОИС-ВС, позволяющие синтезировать:

- персонифицированные подсистемы поддержки социально-экономических и правотворческих решений;
- системы правового сопровождения объектов промышленной собственности (ОПС: изобретений, полезных моделей, промышленных образцов) в открытом сетевом пространстве Интернет/Интранет;
- программного обеспечения обучаемых оболочек с интеллектуальными свойствами для заданной предметной области и ОИС.

В результате показано, что разработанные методики и модели экспертизы современных информационных технологий позволяют с большой степенью объективности оценить не только ту или иную спроектированную позиционную систему программного управления процессами взаимодействия ЛПП-ОИС в ИСАПР, но и синтезировать прогностические и оценочные характеристики ОПС и ОИС различного характера на базе адаптации разработанной библиотеки программных загрузочных модулей.

Литература

1. Беккер Г.С. Экономический анализ и человеческое поведение. – М.: Наука. 1993.
2. Bradshaw J.W., Duffield S., Benoit P. et al. KAoS: Toward an industrial - strength generic agent architecture // Software Agents. Cambridge MA: AAAI/MIT Press, 1996.
3. Лукницкий С.П. Средства массовой информации как охранная грамота власти. – М.: Русский Двор, 2003.
4. Ботуз С.П. Автоматизированный синтез нейроподобных структур и моделей идентификации нелинейных динамических процессов в Internet. – В кн.: Математические методы распознавания образов (ММРО – 9)/ Под ред. акад. РАН Ю.И. Журавлева. – М.: ВЦ РАН, 1999.
5. Ботуз С.П. Методы и модели экспертизы объектов интеллектуальной

- собственности в сети Internet. – М.: Солон-Р, 2002.
6. Ботуз С.П. Математические модели идентификации объектов и субъектов промышленной собственности в сети Интернет. – В кн.: Математические методы распознавания образов-10 (ММРО-10)/ Под ред. акад. РАН Ю.И. Журавлева. – М.: ВЦ РАН, 2001.
 7. Ботуз С.П. Методы проектирования и экспертизы технически оптимальных позиционных систем программного управления. Автореф. дис.... докт. техн. наук. – М.: МИЭМ, 2003. – 30 с.

Выбор начальной точки процесса векторизации контурных изображений в задачах распознавания

А.В. Бутвина

(Москва)

В работе предлагается контурные изображения подвергать векторизации, то есть представлять их в параметрической форме для дальнейшего аналитического описания и реализации алгоритмов распознавания образов. Вообще процесс параметрического представления контурных изображений можно начинать с любой точки на контуре. Полученные проекции целесообразно описывать отрезками ортогонального ряда с точностью, обеспечивающей уверенное различение заданных деталей контура. При таком аналитическом описании коэффициенты разложения будут содержать необходимую информацию об особенностях контурного изображения и могут служить формальными признаками для распознавания конкретного контурного изображения. Если на конкретном контуре будет выбрана начальная точка по каким-то критериям, которые позволяют ее всегда перед началом векторизации уверенно определять, а обход контура при векторизации будет осуществляться по часовой стрелке, то исходные коэффициенты разложения (при обучении) будут связаны с новыми коэффициентами разложения (при распознавании) строгими соотношениями [1]. Кроме того легко выводятся инвариантные соотношения, существенно облегчающие процесс векторизации. В докладе рассматриваются критерии для устойчивого помехоустойчивого определения начальной точки векторизации на нескольких различных контурных изображениях, составляющих анализируемую сцену. При это учитывается, что на контурные изображения могут быть наложены высокочастотные помехи. Рекомендуется воспользоваться при этом формулой расстояния между элементами метрического пространства [2]. Проводимые исследования выполняются при финансовой поддержке РФФИ (номера проектов: 01-07-97060, 01-07-90317, 01-01-00894).

Литература

1. Ф.Ф.Дедус, С.А.Махортых, М.Н.Устинин, А.Ф.Дедус. Обобщенный

- спектрально-аналитический метод обработки информационных массивов.// М. Машиностроение. 1999. с.356.
2. А.Н.Колмогоров, С.В.Фомин. Элементы теории функций и функционального анализа.// М. Наука. 1968.

Архитектура системы представления зрительных динамических сцен в терминах понятий

М.Н. Вайнцвайг, М.Н. Полякова

(Москва)

Система представления зрительных динамических сцен в виде иерархических структур понятий, строится на основе *внутреннего языка*, единообразно использующего как геометрические примитивы (контуры, направления и пр.), так и формируемые в процессе обучения семантические понятия более высокого уровня (“дом”, “дерево”, “человек”, “бег” и пр.).

Основной целью такого представления является сжатие хранящейся в памяти информации с обеспечением возможности ее обработки в реальном времени за счет:

- распараллеливания вычислений;
- введения коротких имен для часто используемых подструктур;
- представления характеристик однотипных подструктур средними значениями, дисперсией и относительными преобразованиями базисов.

Язык представляет собой набор операторов, результатом работы которых является формирование структурных представлений, отражающих взаимосвязи разного рода объектов (предметов, траекторий их движения, изменения и пр.).

Работа системы основана на взаимодействии двух ее блоков - *входного анализатора* и *ассоциативной памяти*, связанных между собой *полем внимания*.

Входной анализатор, представляющий собой систему полей процессоров, реализует элементарные операторы языка, выполняет предварительную обработку сенсорных картин, преобразуя их в *объекты памяти*, т.е. элементы структурно-языковых выражений.

Решая задачи стереосинтеза и строя пирамиду $2.5D \times \Delta t$ картин различных уровней разрешения, он на основе пространственно-временных производных и градиентов на каждом из уровней производит:

- выделение особенностей (границ, траекторий движения, элементов текстуры и пр.);
- вычисление направлений границ, скоростей и направлений движения, кривизн, углов и пр.,
- разбиение картины на области однородности (по цвету, текстурам, скоростям и направлениям движения и пр.);

- связывание объектов и их характеристик отношениями равенства, включения, объект-подобъект, общности границ, соотношениями координат, характеристик динамики и пр.;

- вычисление важностей объектов (в частности, на основе пространственно-временного контраста).

Ассоциативная память представляет собой семантическую сеть - граф, каждой вершине которого соответствует процессор, хранящий и обрабатывающий информацию о некотором объекте O_i .

Ребрам графа соответствуют связи между процессорами, одновременно реализующие разного рода операция или отношения (равенства, включения, соотношения уровней или координат объектов, преобразований их базисов, скоростей и пр.). Таким образом, ассоциативная память служит как местом хранения структурной информации, так и распределенным устройством, осуществляющим ее параллельную (ассоциативную) обработку.

Конечными результатами ассоциативной обработки являются: обучение, т.е. основанное на обобщении формирование понятий, а также использование этих понятий для представления и интерпретации вновь наблюдаемых сцен.

Поле внимания служит как бы регистром обмена между входным анализатором и ассоциативной памятью. В него в каждый момент времени t по максимуму важности вместе с вектором переключения внимания V^t поступает некоторый объект O^t либо из входного анализатора, либо из ассоциативной памяти. (В качестве таких объектов могут использоваться предметы, соотношения, цели, задачи и пр.)

Попав в поле внимания, объект O^t и вектор V^t поступают одновременно:

а) во входной анализатор, в результате чего на его полях производится коррекция распределения важности объектов O_i ,

б) в ассоциативную память, где производится его запоминание и сопоставление с каждым из объектов памяти O_j .

При запоминании, в соответствии с вектором V^t , строятся связи O^t с другими объектами, формирующие структурное представление ситуации. При этом структура каждого объекта задается в его относительном базисе, когда все расстояния приводятся к размеру области объекта при сохранении относительных направлений. Это обеспечивает возможность распознавания предметов инвариантно к ракурсам их наблюдения.

В зависимости от новизны объектов, они могут отражаться в памяти как непосредственно - в виде элементарных понятий, формируемых входным анализатором, так и на основе ассоциативного сопоставления с использованием таких сложных обобщенных понятий как "дом", "дерево" и

пр. В последнем случае в записи будут фигурировать идентификаторы, физически связанные с местами хранения соответствующих структур, в результате чего может запоминаться лишь наиболее важная и не обязательно конкретная информация о ситуации.

Ассоциации служат основной процедурой, используемой как в процессе формирования понятий, так и при интерпретации сцен в терминах этих понятий.

В результате ассоциаций для структур памяти вычисляется:

а) *величина ассоциации* - мера сходства с входным описанием, интегрально учитывающая:

- близость векторов характеристик объектов входа и памяти;
- близость относительных преобразований реперов этих объектов;
- важность объектов.

б) *след ассоциации* - выделяющий подмножество объектов, общих для входного и хранящегося в памяти описания.

Для обеспечения ассоциаций каждому объекту памяти O_j , кроме его непосредственного описания, сопоставлен набор дополнительных характеристик, значения которых вычисляются при каждом переключении внимания, а именно:

- близость $r_j^t = r(O_j, O^t)$ к объекту внимания, определяющая принадлежность следу ;

- близости $q_k^t = q(V_k, V^t)$ отношений с соседними (по связям) объектами O_k ,

- величина ассоциации $a_j^t = \max_k (0, a_j^{t-1} - c, q_k^t \cdot a_k^t + r_j^t)$, ($c \ll 1$),

определяющая важность, по максимуму которой на след ассоциации обращается внимание.

Вычисление этих характеристик происходит на основе одновременной пересылки:

а) объекта внимания и вектора переключения внимания - ко всем объектам памяти;

б) от каждого объекта - к его соседям информации о важности, величинах ассоциации и преобразованиях пространственно-временных базисов объектов.

Формирование понятий основано на пропорциональном величинам ассоциации увеличении весов объектов, принадлежащих следам ассоциаций, в результате чего понятия строятся в виде часто встречающихся подструктур, состоящих из достаточно важных объектов.

Сравнительный анализ методов сегментации кожи на цветных изображениях

В.П. Вежнев, А.А. Андреева, А.А. Дегтярева
(Москва)

Сегментация изображений находит множество применений в различных задачах машинного зрения и обработки изображений. Сегментация является предварительным этапом функционирования любой системы обработки изображений, так как позволяет упростить последующий анализ однородных областей изображения, их яркостных, цветовых и геометрических характеристик. Сегментацию можно рассматривать как начальный этап построения формального описания сцены, качество выполнения которого во многом определяет успех решения задачи распознавания изображений, интерпретации и идентификации объектов сцены.

Сегментация полутоновых изображений является хорошо изученной областью, с множеством разработанных алгоритмов, основанных на различных принципах. Сегментация цветных изображений является более сложной задачей, поскольку в этом случае приходится работать с многомерным признаковым пространством.

На практике, алгоритмы сегментации цветных изображений применяются в различных задачах. Таких, например, как анализ аэрофотоснимков, распознавания печатного и рукописного текста, распознавание и отслеживание перемещения некоторых объектов на изображении и в видеопотоке. Важным частным случаем применения цветовой сегментации является распознавание участков кожи человека на фотоснимках. Алгоритмы автоматического распознавания областей кожи на изображениях находят применение при решении задач анализа медицинских изображений (например, идентификация злокачественных опухолей и заболеваний кожи), автоматической локализации лица человека на фотографии и в видеопоследовательностях для построения систем распознавания лиц и жестов, для алгоритмов сжатия видео адаптирующихся к содержанию видеопотока и т.п.

Алгоритмы сегментации кожи основываются на использовании модели распределения оттенка кожи в выбранном цветовом пространстве. Выбор адекватной модели и определение ее параметров производится по набору тренировочных изображений. С помощью полученной таким образом модели производится сегментация участков кожи на обрабатываемых изображениях путем последовательной проверки цвета каждого пикселя на принадлежность оттенку кожи и последующему объединению «кожных» пикселей в связные области. Было разработано множество различных моделей распределения цвета кожи, однако классификации и сравнительного анализа их производительности не проводилось.

Встречающиеся в литературе методы моделирования цвета кожи можно разделить на три широких семейства:

1. Априорно заданная область в цветовом пространстве [1 - 3]
2. Непараметрические модели распределения оттенка кожи [4]
3. Параметрические модели распределения оттенка кожи [5]

В случае априорно заданной области используется набор неравенств, которым должны удовлетворять координаты цвета в выбранном цветовом пространстве для того, чтобы данный цвет был отнесен к оттенку кожи. В большинстве случаев неравенства вычисляются исследователями «вручную», на основании опыта и экспериментов, однако недавно появилась работа [2], использующая методы машинного обучения для автоматического выбора цветового пространства и составления набора классифицирующих неравенств.

Непараметрические модели вычисляют и хранят вероятности принадлежности к оттенку кожи каждой точки дискретизированного цветового пространства. Вероятности рассчитываются исходя из накопленных тренировочных изображений с областями кожи, выделенными вручную.

Параметрические модели используют явное представление распределения цвета кожи (например, бимодальное нормальное, смесь нормальных и т.д.) в выбранном цветовом пространстве. Параметры модели вычисляются на основании тренировочных данных – изображений с выделенными областями кожи.

Каждое из семейств методов есть свои недостатки и достоинства, подробно рассмотренные в статье [6]. В данном докладе будут представлены результаты тестирования производительности различных методов моделирования цвета кожи на достаточно обширном наборе тестовых изображений. Сравнение различных моделей сегментации проводится по следующим критериям: соотношение вероятности правильного и ложного обнаружения кожи (кривая рабочих характеристик метода), скорость тренировки и работы, занимаемая память, зависимость от выбора цветового пространства, в котором проводится классификация.

Литература

1. Peer, P., Kovac, J., Solina, F. “Human skin colour clustering for face detection”. Submitted to EUROCON 2003 – International Conference on Computer as a Tool, 2003.
2. Gomez G., Morales E., “Automatic feature construction and a simple rule induction algorithm for skin detection”, In Proc. of the ICML Workshop on Machine Learning in Computer Vision, pp. 31-38, 2002.
3. Jordao, L., Perrone, M., Costeira, J., Santos-Victor, J. “Active face and feature tracking”, In Proceedings of the 10th International Conference on Image Analysis and Processing, pp. 572-577, 1999.

4. B. D. Zarit, B. J. Super, and F. K. H. Quek , “Comparison of five color models in skin pixel classification”. In *Proceedings of the International Workshop on Recognition, Analysis, and Tracking of Faces and Gestures in Real-Time Systems*, pp. 58-63, Kerkyra, Greece, September 1999.
5. Terrillon, J.-C., Shirazi, M. N., Fukamachi, H., Akamatsu, S. “Comparative performance of different skin chrominance models and chrominance spaces for the automatic detection of human faces in color images”, In Proc. of the International Conference on Face and Gesture Recognition, pp. 54-61, 2000.
6. Vezhnevets V., Sazonov V., Andreeva A, “A Survey on Pixel-Based Skin Color Detection Techniques”, Материалы конференции Графикон-2003, 2003 г.
7. Вежневек В., “Локализация человеческого лица на цветном растровом изображении”, тезисы доклада, Материалы конференции ММРО-10, стр. 181-183, 2001 г.

Программный комплекс для проектирования экспертных систем «ExSys».

Д.П. Ветров, Д.А. Кропотков
(Москва)

Введение

В различных областях человеческой деятельности, таких как медицина, экономика, социология, физика, биология для решения задач интеллектуального анализа данных и обработки информации часто используют экспертные системы. Основной отличительной особенностью таких систем является наличие некоторой априорной информации об исследуемом процессе, получаемой от экспертов. В теории логического управления эта информация получила название базы знаний. Исследования в области экспертных систем ведутся с середины 50-х годов прошлого столетия, и за это время был реализован целый ряд успешных проектов по созданию подобных систем, работающих на практике [1]. Большинство из них следует отнести к области систем, построенных на принципах нечеткой логики. Однако каждый раз такие проекты требовали специальных трудозатрат и денежных вливаний. Эксперты прикладных областей знаний, которые сами не являются специалистами в теории распознавания образов, предпочитают пользоваться готовыми программными продуктами, реализующими общие и достаточно простые механизмы проектирования экспертных систем. Среди подобных программных продуктов общего пользования стоит выделить, прежде всего, пакет fuzzy logic toolbox системы MatLab [2]. Среди его недостатков можно отметить его склонность к переобучению и низкие результаты прогнозирования в реальных задачах [5], длительное время работы и высокие требования к производительности

вычислительной системы, требование специальной подготовки пользователей, а также отсутствие гибкости и простоты использования системы, связанное с консервативностью выбора теоретических основ обработки нечеткой информации. К числу последних стоит отнести в первую очередь необходимость задания формы и размеров нечетких множеств, используемых в системе, а также так называемый нейро-нечеткий подход к генерации нечетких правил, при котором у эксперта не остается возможности внести какие-либо изменения в базу знаний системы.

В виду указанных проблем появилась идея создания универсального программного комплекса для проектирования экспертной системы, позволяющего исследователям проходить все этапы создания системы в интерактивном режиме. Кроме того, он должен обходить недостатки, указанные для случая системы MatLab.

Структура системы

В основе экспертной системы «ExSys» («EXpert SYstem») лежит общая теория построения нечетких экспертных систем [1], [3], а также ряд специальных методов автоматического формирования структуры нечетких множеств и генерации нечетких правил, развиваемых в работах [4], [5]. Общая структура программного комплекса представлена на рисунке 1.

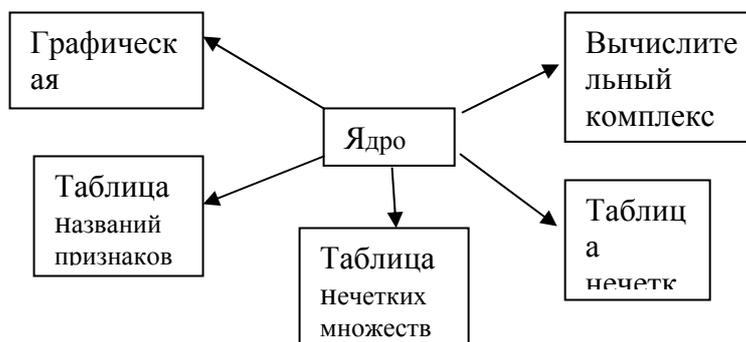


Рис 1. Общая схема программы.

Система состоит из нескольких модулей, каждый из которых осуществляет свою функцию. Ядро является основным модулем, который осуществляет связь всех модулей и обмен данных между ними. Таблицы названий признаков, нечетких множеств и нечетких правил представляют собой стандартные таблицы базы данных типа Paradox и хранят в себе информацию о названиях признаков, регулярных разбиениях признаков и названиях нечетких множеств, список нечетких правил соответственно. Посредством графической оболочки эксперт контролирует все этапы проектирования системы.

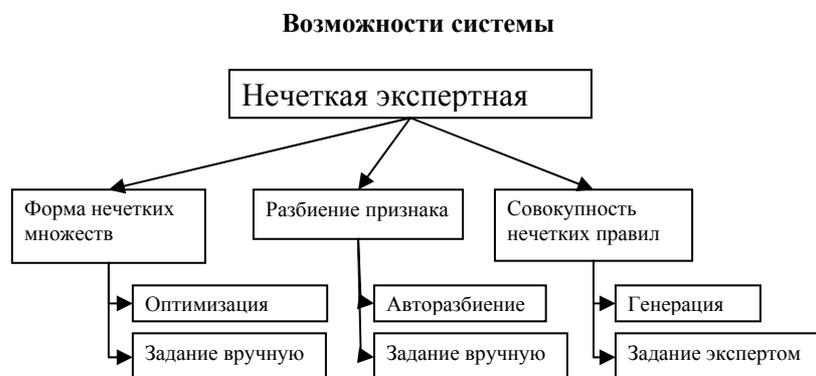


Рис. 2. Возможности системы.

В зависимости от того, на что способен эксперт, данная система может работать в нескольких режимах (рис. 2). В том случае, когда отсутствует какая-либо априорная информация об исследуемой области, все необходимые шаги могут быть проведены в автоматическом режиме. Пользователь должен лишь указать число нечетких множеств для каждого признака и, быть может, дать им названия. В случае необходимости, эксперт может определить примерные границы между множествами вручную. Совокупность нечетких правил вывода (база знаний) генерируется автоматически с использованием таблицы прецедентов или/и вводится экспертом. Он также в случае необходимости может изменить посылки или веса некоторых правил. Форма нечетких множеств определяется путем процедуры оптимизации. Различные режимы работы системы представляются от полностью автономного режима до случая, когда все нечеткие множества и правила вывода задаются экспертом. В последнем случае система функционирует как классический нечеткий контроллер [3].

Нечеткая экспертная система «ExSys» позволяет:

- Задавать регулярное разбиение признаков пространства в интерактивном режиме либо генерировать его автоматически
- Определять форму нечетких множеств вручную либо путем оптимизации по прецедентам
- Создавать базу знаний системы через интерактивный интерфейс, а также путем генерации методом эффективных сужений с различным набором параметров
- Отображать все данные внутри системы через стандартные таблицы базы данных типа Paradox.

В созданном программном продукте реализованы все изначально поставленные цели. Он является удобным инструментом для разработки и тестирования нечетких экспертных систем.

Литература

1. Тэрано Т., Асаи К., Сугено М. Прикладные нечеткие системы. Мир, Москва, 1993.
2. Дьяконов В., Круглов В. Математические пакеты расширения MATLAB. Специальный справочник. Питер, Москва, 2001.
3. Перфильева И. Приложения теории нечетких множеств // Итоги науки и техники. Том 29. Серия Теория вероятностей. Математическая статистика. Теоретическая кибернетика. ВИНТИ, Москва, 1990, с.83-151.
4. Ветров Д., Кропотов Д. Об использовании прецедентной информации в нечетких экспертных системах // Труды 6-ой международной конференции «Распознавание образов и анализ изображений: новые информационные технологии» (РОАИ-6-2002). НовГУ им. Ярослава Мудрого, Великий Новгород, 2002, с. 100-104.
5. Kropotov D., Vetrov D. One Approach To Fuzzy Expert System Construction // Proceedings of fifth International Conference On Enterprise Information Systems (ICEIS-2003). Escola Superior de Techologia do Instituto Politecnico de Setubal, Setubal, 2003, pp 566-570.

Некоторые аспекты прогнозирования результатов агроэкологически верных вариантов земледелия в реальных условиях хозяйства

Л.М. Воронова, Ю.И. Журавлев
(Владимир, Москва)

Логистические приемы проектирования некоторого объекта предполагают работу с тремя составляющими: морфологией системы (структурными компонентами), синтаксисом (связями компонент) и семантикой (согласованностью связей). Рассматриваемая нами морфологическая система (МС) - это "Система земледелия" реального хозяйства. Как показано в [1], решена задача классификации многопризнаковых объектов МС в виде морфологического ящика (МЯ): совокупность признаков, каждый из которых - вектор его возможных значений. Одновременно это - модель, "вмещающая" все множество возможных объектов МС в рамках вложенных в нее знаний. Формализация функциональных требований к МС в виде синтаксической структуры позволила использовать логику для синтеза вариантов решения. Разработана порождающая грамматика (алфавит, правила подстановок, порядок их применения), регламентирующая синтаксические правила связи компонент в рамках целого, позволяющая генерировать все (даже практически непригодные с точки зрения опытного агронома) варианты земледелия. Поэтому необходимо учесть семантику земледелия.

Все специфические условия взаимосвязей компонент были включены авторами прямо в МЯ. Это расширило и усложнило его строение (в отличие от классического МЯ): вектор значений каждого признака трансформирован в матрицу, каждая строка которой – “гнездо” из двух частей. Левая – условия, отражающие семантические связи значения признака с выборами, сделанными на предыдущих шагах; правая – расширенное значение признака вместе с его характеристиками, важными для условий на последующих выборах. Так, одно из “гнезд” матрицы-признака “рабочие_поля” в МЯ может быть представлено следующим образом:

Таблица. “Рабочие поля”.

Условия	Признак				
	Значение	Характеристики			
		№ с/о	№ в с/о	Площадь	Тип земли
.....
№15 №11 с/о5	2уч-ка:1и15	5	3	112	1.1
.....

В лингвистике семантика формируется в тезаурусе, упрощенно интерпретируемом как словарь с описанием смысловых связей. В нашем случае роль тезауруса берет на себя сформированный расширенный МЯ. Если правую часть “гнезда” любой матрицы рассматривать как некоторое логическое высказывание, то на языке логики предикатов оно включает субъект (значение признака) и предикат – функцию субъекта, выражающую его основные свойства, характеристики. В таком случае каждая матрица определяет некий предикат: “правильные характеристики значения” и содержит лишь истинные значения предиката для любого значения своего признака.

Включая в рассмотрение логического высказывания левую часть “гнезда” (условия), получаем новый предикат: “от условия для каждого значения очередного признака к его правильной характеристике”. Так как условия формируются из значений или характеристик других признаков (субъектов), определяемых предыдущими подстановками, то в общем случае они отражают отношения связи между предметами (в нашем случае между признаками системы). Поскольку для любого значения признака указаны лишь “истинные” условия его выбора, можно констатировать, что каждая матрица МЯ содержит лишь множество истинности своего признака. Теперь множество выводимых в грамматике терминальных цепочек будет содержать лишь “правильные” варианты системы земледелия.

Предлагаемый подход моделирования земледелия лежит в основе разработки специализированного программного продукта. Реализован механизм "фильтрации" МЯ через "запреты" и "требования" на значения признаков в техническом задании (ТЗ), которые можно указать наряду с

обязательными данными по проектированию. Это сразу исключает генерацию не пригодных для конкретной ситуации в хозяйстве вариантов земледелия, сокращая и их количество, и время синтеза. Реализуется вариант представления ТЗ и иллюстрации результатов в среде ГИС.

Оценка качества осуществляется по затратам, доходу, прибыли и по урожаю культур. Аналитическая часть также строится на базе знаний и опыта работы по прогнозированию результатов в данной предметной области, так как значения признаков, а часто и их конкретные сочетания вносят определенный вклад в вычисляемые оценки. Используя эти прогнозы на предстоящий период, можно выполнить отбор вариантов по различным критериям, выбрать наиболее подходящие.

Практическое использование системы возможно хозяйством, в котором изучены земли на основе единой методики агроэкологической типизации и проведена соответствующая идентификация ареалов агроландшафтов.

Литература

1. Voronova L.M., Zhuravlev Yu. I. An Approach to the Automated Design of Agricultural Systems // Pattern Recognition and Image Analysis. Vol. 13, No. 2, 2003, pp. 384-386.

Анализ сцен на основе применения древовидных представлений изображений

С.Н. Ганебных, М.М. Ланге

(Москва)

Введение

В работе [1] предложен подход для быстрого распознавания одиночных образов в виде двумерных тел достаточно сложной формы. Разработанный подход основан на формировании инвариантных описаний (представлений) образов наборами древовидно структурированных геометрических примитивов и поиске в словаре ближайших эталонов для распознаваемых образов. Словарь организован в форме кодового дерева представлений эталонных образов, а поиск эквивалентен процедуре декодирования по критерию наименьшего различия предъявленного образа с эталоном.

В настоящей работе предлагается технология анализа сцен, содержащих произвольное число объектов. Развиваемая технология использует древовидные представления изображений сцен и образов отдельных объектов. Применение таких представлений позволяет существенно уменьшить вычислительные затраты на выделение образов в изображении сцены и оптимизировать сложность идентификации выделенных образов со словарными эталонами.

Задача исследования и пути ее решения

Рассматриваются сцены, заданные двухуровневыми изображениями,

которые содержат образы несвязных объектов в виде произвольно ориентированных тел. Число объектов сцены (образов) заранее неизвестно, но уровень яркости образов отличается от уровня яркости фона. Для определенности будем считать, что фон представлен нулевыми пикселями, а образы – единичными. Пример изображения модельной сцены из четырех объектов дан на рис. 1.

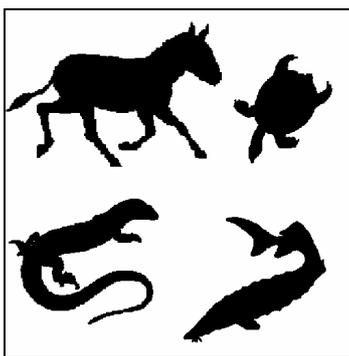


Рис. 1.

Задача анализа сцены состоит в определении числа ее объектов и принятии решения по каждому объекту на основе распознавания их образов. Решение задачи включает следующие этапы обработки и анализа изображения сцены.

1. Выделение на изображении наименьшего числа компактных образов, элементы которых удовлетворяют условию связности.

2. Построение инвариантных представлений выделенных образов на основе их разбиения на сегменты и аппроксимации сегментов примитивами с гарантированной точностью.

3. Независимое кодирование представлений образов сцены кодовыми словами со свойством префикса (ни одно кодовое слово не является началом другого).

4. Поиск в кодовом дереве эталонных образов (словаре) ближайших представителей для закодированных образов сцены методом их декодирования по критерию наименьшего различия со словарными эталонами.

Для уменьшения вычислительной сложности обработки этап 1 целесообразно реализовать на квадродревовидном представлении изображения, которое позволяет проверять на связность не пиксели, а укрупненные фрагменты изображения, соответствующие концевым вершинам квадродерева [2].

Представление образа примитивами (этап 2) должно удовлетворять требуемой точности и сохранять инвариантность относительно аффинных преобразований. Кроме того, такие представления должны независимо

кодироваться кодовыми словами (этап 3), средняя длина которых по множеству образов стремилась бы к минимально возможной величине, когда число образов растет. Такое кодирование позволило бы организовать поиск в словаре ближайших эталонов к распознаваемым образам с наименьшими вычислительными затратами (этап 4).

Для выполнения указанных требований использованы древовидные представления образов, строящиеся в их собственных координатных осях [1], а словарь формируется в виде кодового дерева эталонных образов, которые образуют эпсилон-сеть [3] в пространстве выбранных древовидных представлений. Для организации поиска в словаре использована модификация алгоритма Витерби [4].

Основные результаты

Результаты последовательных этапов обработки и анализа исходного изображения сцены (рис. 1) иллюстрирует рис.2.

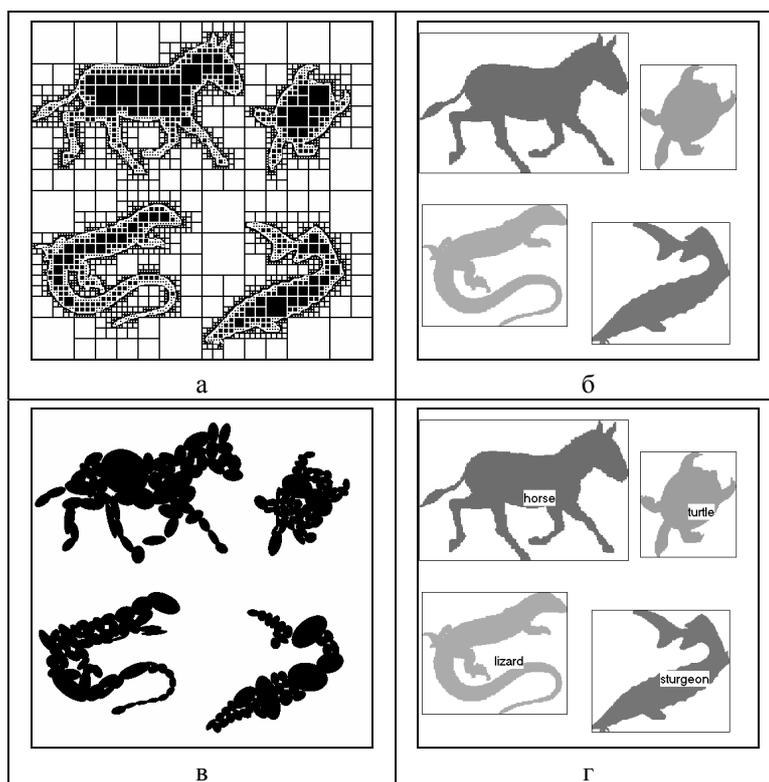


Рис.2

К ним относятся: получение квадродревовидного представления

изображения с заданной допустимой погрешностью (а); выделение четырех образов путем слияния связанных фрагментов в квадродереве (б); построение инвариантных представлений выделенных образов наборами древовидно структурированных эллиптических примитивов и независимое префиксное кодирование таких представлений (в); результаты распознавания образов сцены ближайшими словарными эталонами (г).

При равновероятных нулевых и единичных пикселах изображения размера $N \times N$ его квадродревовидное представление с нулевой погрешностью уменьшает число фрагментов в среднем до $1/4 N^2$ по сравнению с числом пикселей N^2 . С увеличением различия указанных вероятностей и допустимой погрешности представления этот эффект увеличивается. При погрешностях 0,1 - 0,2 уменьшение числа смысловых единиц (фрагментов) в квадродереве приводит к снижению на порядок вычислительных затрат на процедуру выделения образов на изображении.

Инвариантные представления образов наборами эллиптических примитивов строятся методом рекурсивного разбиения образов на областные сегменты и аппроксимации получаемых сегментов с заданной допустимой погрешностью согласованными с ними примитивами. Инвариантность достигается совмещением собственных координатных осей сегментов и примитивов и нормировкой параметров аппроксимирующих примитивов. Рекурсивность процедуры сегментации образов обеспечивает формирование представлений образов в виде совершенных бинарных деревьев, в которых каждая промежуточная вершина порождает две вершины следующего уровня. Свойство совершенности представляющих деревьев позволило построить для них независимое префиксное кодирование с длинами слов, равными числам вершин в соответствующих деревьях.

Предложенный способ кодирования порождает словарь эталонных образов в форме q -арного кодового дерева с асимптотически минимальной средней длиной, равной $\log_q M$, где M и q – соответственно размеры словаря и кодового алфавита. Для хранения такого словаря требуется память порядка $O(M)$, причем он может пополняться новыми эталонами без перекодирования записанных ранее. Применение модификации алгоритма Витерби для поиска в указанном словаре приводит к вычислительной сложности поиска порядка $O(\log_q M)$. Для сравнения, переборная процедура поиска ближайшего эталона в списке требует $M \log_q M$ вычислений. Объем памяти для хранения списка эталонов также превосходит объем памяти для хранения словарного дерева и составляет

$M \log_q M$ вместо $O(M)$, требуемого для хранения дерева.

Работа выполнена при поддержке РФФИ, гранты: 01-07-90308, 03-01-00583.

Литература

1. Lange M.M. and Lange A.M. Invariant Representation and Tree Encoding of Patterns for Their Fast Search in a Dictionary // Proceedings of The 5th International Conference on Pattern Recognition and Image Analysis, PRIA-5-2000. Samara, 2000. Vol. 2, pp. 428-433.
2. Jackins C.L., Tanimoto S.L. Quad-trees, Oct-trees and K-trees: A Generalized Approach to Recursive Decomposition of Euclidean Space // IEEE Transactions on PAMI, 1983. Vol. 5, no. 5, pp. 533-539.
3. Колмогоров А.Н., Тихомиров В.М. Эпсилон-энтропия и эпсилон-емкость множеств в функциональных пространствах // Теория информации и теория алгоритмов. М.: Наука, 1987. С. 119-198.
4. Блейхут Р. Быстрые алгоритмы цифровой обработки сигналов // М.:Мир, 1989. 448 с.

Сравнительное исследование эффективности различных описаний речевых сигналов в задаче верификации

дикторов

В.В. Геннер, А.С. Хайдар

(Санкт-Петербург)

Верификация дикторов по речевому сигналу состоит в решении задачи о том, является ли диктор тем, за кого себя выдает [1]. Обычно процесс использования системы верификации состоит из двух шагов. Первый шаг заключается в регистрации клиента, когда записывается одна или несколько тестовых речевых фраз сказанных этим человеком. Эти записи используются системой для обучения и создания так называемой модели клиента. Вторым шагом является сам процесс верификации, когда пользователь говорит некоторую фразу и которая используется системой верификации для сравнения с моделью клиента для принятия решения о пропуске или отклонении. При этом пользователь в каком-то виде идентифицирует себя, чтобы система могла выбрать нужную модель клиента для сравнения.

В настоящей работе рассматриваются исследования с использованием разработанной системы верификации дикторов на основе нейронной сети (НС). При регистрации в системе с микрофона записывается несколько повторений речевого фрагмента (парольной фразы) клиента. Из этих входных записей извлекаются последовательности наборов характеристик. Характеристики должны наиболее полно описывать записанные речевые фрагменты, содержать как можно больше информации об индивидуальности клиента и не сильно зависеть от условий записи (шумов, разного

оборудования и т.д.). Так как полный набор характеристик содержит большое количество избыточной информации (которая может даже повредить правильному решению задачи верификации) из него выбирается подмножество наиболее значимых характеристик, которые и будут описывать каждый речевой фрагмент. Затем, с использованием входных последовательностей характеристик строится эталон, который может быть как просто одной из входных последовательностей, так и усреднением всех имеющихся входных последовательностей. К этому эталону нелинейно приводятся все входные записи, таким образом, чтобы у них у всех была одинаковая длина, а различие с эталоном было минимальным. Таким образом, к этому моменту у нас есть эталон и несколько последовательностей характеристик для каждого повторения. После этого строится нейронная сеть, для которой в качестве обучающего множества поступает имеющийся набор последовательностей характеристик регистрируемого клиента, а также последовательности характеристик других дикторов, выбранные из речевой базы данных и приведенные к эталону. На сформированном множестве НС учится отличать регистрируемого клиента от всех остальных. Когда количество ошибок станет незначительным, т.е. сеть обучится, мы получим модель клиента, состоящую из весовых коэффициентов обученной сети и эталона. Эту модель дальше можно использовать для верификации зарегистрированного клиента, а исходные последовательности характеристик этого клиента (ненормализованные) записываются в общую речевую базу для использования при обучении следующих клиентов.

Схема верификации зарегистрированного клиента выглядит следующим образом. Из поступившей записи извлекается полный набор характеристик. Из полного набора на основе модели клиента выбирается подмножество значимых характеристик, которое приводится к эталону модели клиента. Веса связей нейронной сети устанавливаются из модели клиента. Дальше нормализованная входная последовательность поступает на вход сети. Выходное значение НС сравнивается с порогом, и на основе этого сравнения принимается решение о пропуске или отклонении тестируемого диктора.

В данной работе основными задачами исследования были: выбор характеристик для описания речевых фрагментов, определение информативного подмножества характеристик.

В качестве основного подхода к построению описания речевого сигнала в системе верификации исследовались различные типы кепстральных описаний.

Кепстральные коэффициенты как представление спектральных характеристик наиболее часто используются в задачах верификации диктора, так как они обеспечивают наиболее точное представление речи как в тихих условиях, так и под воздействием шумов.

Исследовалась эффективность применения трех видов вычисления

кепстральных коэффициентов (КК): кепстр на основе быстрого преобразования Фурье с использованием Mel-частотной шкалы (Mel кепстр БПФ), кепстр на основе коэффициентов линейного предсказания (кепстр КЛП) и кепстр КЛП на основе Mel-шкалы (Mel кепстр КЛП). Mel-шкала соответствует логарифмическому сжатию частотного диапазона:

$$m = 1125 \log(0.0016f + 1)$$

где f - частота в спектре, Гц, а m - частота в новом пространстве, Mel.

Результаты экспериментов по выбору наилучших характеристик представлены ниже в таблицах. При этом все результаты были получены для НС, обученной только на 10 из всех 25 клиентов, и для каждого из этих 10 клиентов для обучения НС выбиралось не более 5 записей. При верификации же, использовались все записи всех доступных клиентов. Таким образом, системе предъявлялись записи злоумышленников, о которых она ничего не знала, что максимально приближает условия эксперимента к реальным условиям применения системы верификации.

В таблице 1 показана эффективность работы системы верификации для трех рассмотренных выше типов характеристик. В этом эксперименте использовался набор из 16 первых коэффициентов без вычисления их производных.

Таблица 1.

Тип характеристик:	Ошибка пропуска, %	Ошибка отклонения, %
Mel БПФ КК	0.14	5.5
Mel КЛП КК	0.14	5.5
КЛП КК	1.1	7.0

Как видно из таблицы, результаты для 16 Mel кепстральных коэффициентов не отличаются, в то время как линейный КЛП кепстр сильно им уступает. Ниже приведены результаты верификации при тех же условиях, но при добавлении к 16 кепстральным коэффициентам их первых производных.

Таблица 2.

Тип характеристик:	Ошибка пропуска, %	Ошибка отклонения, %
Mel БПФ КК	0.14	2.0
Mel КЛП КК	0.36	3.5
КЛП КК	1.16	7.5

Результаты показывают значительное преимущество Mel шкалы. Однако

теперь видно, что добавление производных несколько уменьшает вероятность появления ошибок для Mel БПФ КК и почти не влияют на результаты КЛП КК. Так как для простых КЛП кепстральных коэффициентов полученные результаты намного хуже, чем для Mel коэффициентов, больше в этой работе они не будут рассматриваться.

В работе также приводятся результаты исследования влияния количества кепстральных коэффициентов на эффективность распознавания и результаты выбора наиболее информативных признаков.

Литература

1. Bimbot, F. and Chollet, G.. Assessment of speaker verification systems. In Gibbon, D., Moore, R., and Winski, R., editors, *Handbook of Standards and Resources for Spoken Language Systems*, chapter 11. Mouton de Gruyter, Berlin, (1997)

Экспериментальные результаты по выделению графических примитивов в задачах распознавания контурных изображений.

С.В. Геращенко, В.Е. Анциперов
(Москва)

Московский физико-технический институт (www.mipt.ru)

Институт радиотехники и электроники РАН (www.cplire.ru).

В докладе обсуждаются экспериментальные результаты применения алгоритмов последовательной выборочной идентификации [1], [2] для задач распознавания контурных изображений. В основе алгоритмов лежит анализ локальных параметров траектории распознаваемого образа с точки зрения соответствия их заданному набору графических примитивов. Предполагается, что оперативная идентификация локальных характеристик траекторий контуров по заданной системе примитивов позволит эффективно использовать последовательные процедуры, контекстные критерии и т.д. для целей ранней диагностики и сужения подмножеств объектов распознавания. На этой основе могут быть синтезированы системы распознавания изображений более экономичные по сравнению с существующими и позволяющие значительно сократить количество вычислительных операций.

В докладе также обсуждаются технические вопросы реализации алгоритмов последовательной выборочной идентификации, связанные с численной реализацией критериев подобия, проблемами масштабирования, созданием банка данных для графических примитивов и т.д. Особое внимание уделено вопросам робастности (устойчивости) результатов распознавания при поворотах и сдвигах контурных образов, а также устойчивости к фоновым (шумовым) искажениям.

Литература

1. В.Е.Анциперов. Метод последовательной выборочной идентификации сигналов. Радиотехника и электроника. т.40, N 5, 1995.
2. В.Е.Анциперов. Оптимизирующее свойство метода последовательной выборочной идентификации. Радиотехника и электр. т.41, N 2, 1996.

Прогнозирование аномальных режимов динамических электромеханических систем методами распознавания образов

Ю.И. Горелов, В.А. Сушкин

(Тула)

Задачи прогнозирования возникновения аномальных режимов технических систем приобретают все большее значение в современной экономической обстановке в связи с так называемой проблемой старения технологического оборудования. В настоящем докладе предлагается один из возможных подходов к решению этой задачи методами распознавания образов. В качестве объекта изучения рассматриваются электромеханические динамические системы, в частности турбогенераторы тепловых электростанций.

Ограничение класса динамических систем электромеханическими системами приводит к тому, что для подкласса алгоритмов распознавания (преобразования информации) могут быть, используемых в качестве прогнозирующих фильтров, могут быть достаточно четко сформулированы локальные и универсальные ограничения [1], что приводит к возможности теоретического анализа корректности и регулярности этих алгоритмов в рамках алгебраической теории Ю.И. Журавлева [2,3].

Дело в том, что динамика любой электромеханической системы может быть достаточно точно описана уравнениями Лагранжа в рамках вариационного подхода [4]. Из теории машин известно, что эффективность функционирования электромеханической системы может быть описана набором значений показателей, представляющих собой энергетические функционалы, зависящие от обобщенных координат, функции Лагранжа, а также некоторых параметров, характеризующих структуру электромеханической системы. При этом аномальным режимам функционирования электромеханической системы может быть поставлено в соответствие множество Парето оптимальных решений задачи многокритериальной оптимизации, в которой в качестве критериев оптимальности выступают эти функционалы.

Ввиду того, что задача поиска Парето оптимального решения в общем случае является некорректно поставленной задачей, то целесообразно по имеющейся предыстории функционирования системы с учетом уравнений

динамики электромеханической системы и конкретного вида энергетических функционалов с применением генетических алгоритмов поиска [5] выделить дискретное множество квази-оптимальных Парето решений. Тогда задача конструирования предсказывающего фильтра, позволяющего прогнозировать времена возникновения и характер аномального режима функционирования электромеханической системы может быть переформулирована как задача синтеза алгоритма преобразования информации (распознавания), использующего в качестве локальных ограничений (априорной количественной информации) объединение множеств неоптимальных и квази-оптимальных Парето решений, а в качестве универсальных ограничений (априорной качественной информации) соотношений, следующих из уравнений, описывающих динамику системы (уравнений Лагранжа) и конкретного вида энергетических функционалов.

Литература

1. Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики. -М.: Наука, 1978. - Вып.33. - С. 5-68.
2. Рудаков К.В. Об алгебраической теории универсальных и локальных ограничений для задач классификации //Распознавание, классификация, прогноз. М.: Наука, 1989. С. 176-201.
3. Vasilyev V.I., Gorelov Yu.I. The Synthesis of Forecasting Filters by Pattern Recognition Learning Methods // Pattern Recognition and Image Analysis, Interperiodica, 1997, vol.7, №3, pp.353 - 368.
4. Ландау Л.Д., Лифшиц Е.М. Теоретическая физика. – М.: Наука, 1965.
5. Растринин Л.А. Адаптация сложных систем. – Рига: Зинатне, 1981.

О критериях оценки поисковых систем

И.С. Городничев

(Москва)

В настоящее время актуальна проблема поиска и анализа информации в больших массивах данных. Один из способов ее решения – структуризация и кластеризация текстов. Существует множество коммерческих систем, которые так или иначе решают эту проблему. В докладе рассмотрены наиболее распространенные критерии оценки поисковых систем и некоторые примеры систем с точки зрения этих оценок.

Критерии оценки поисковых систем

1. Алгоритмическая развитость
 - Возможности кластеризации и классификации
 - Построение семантических сетей
 - Нечеткий поиск

2. Разнообразие исходных данных
 - Какие форматы электронных документов поддерживаются
 - С какими источниками способна работать поисковая система (файловая система, СУБД, системы управления документами, Интернет и т.п.)
 - Сложность адаптации системы к новым источникам и форматам
3. Сложность и настройка поисковых параметров
 - Насколько развит язык построения поисковых запросов
 - Существует ли у пользователя возможность вмешаться в работу поисковой системы с целью уточнения
4. Простой поиск по ключевым словам
 - Насколько эффективно обрабатываются запросы на естественном языке
 - Насколько система проста в использовании без специальных знаний
5. Сложность преобработки данных
 - Какие действия выполняются с документами при их помещении в поисковую систему
6. Возможности использования результатов работы
 - Какие есть возможности по настройке механизма генерации отчётов о результатах поиска
7. Наглядность
 - В какой форме демонстрируются результаты поиска
 - Какие средства визуализации имеет система
8. Открытость
 - Какие имеются средства интеграции системы с приложениями третьих фирм (API и стандарты)

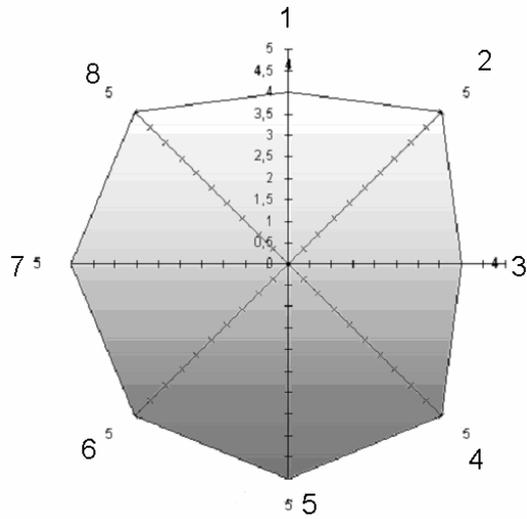


Рис. 1. Autonomy.

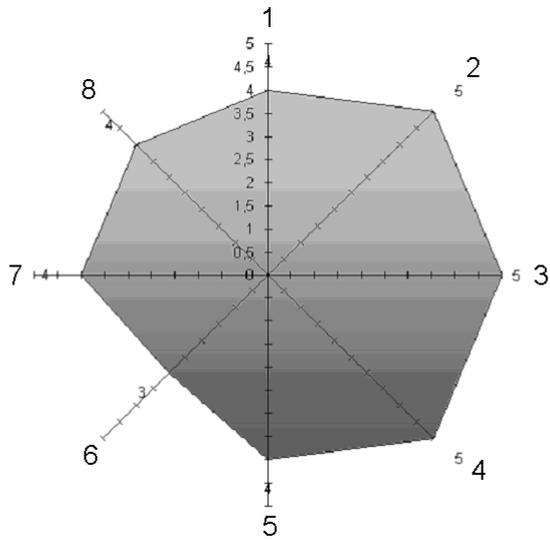


Рис. 2. Convera RetrievalWare.

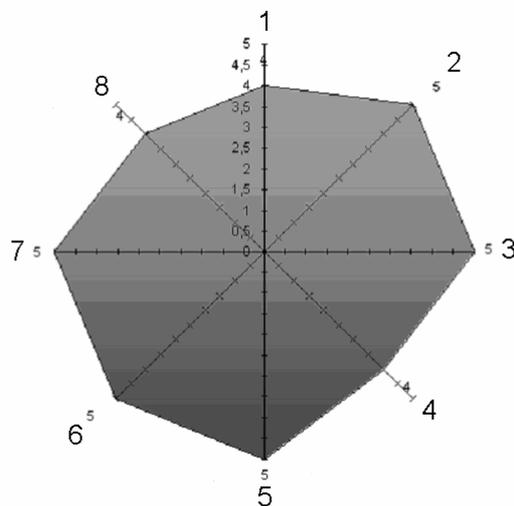


Рис. 3. Verity K2.

Из представленных критериев только первый оценивает алгоритмическую мощность систем. Остальные оценивают эргономические и технологические возможности.

Надо заметить, что основная задача, которую решают эти системы – задача поиска информации, соответственно, механизмы кластеризации текстов часто развиты недостаточно сильно. Проблема усугубляется сложной морфологией русского языка.

Основные технологии, использующиеся в современных коммерческих системах, - это или нейросетевые технологии, или статистические методы типа байесовского метода.

В дальнейших исследованиях автор предполагает применить алгебраический подход для кластеризации текстов и сравнить результаты с результатами работы промышленных систем.

Тестирование алгоритмов предварительной обработки изображений

И.В. Грибков, А.В. Захаров, П.П. Кольцов, Н.В. Котович, А.А. Кравченко, А.С. Куцаев, В.К. Николаев
(Москва)

В данной работе разрабатывается подход к получению оценки качества используемых алгоритмов для одной из задач предварительной обработки изображений, а именно задачи выделения границ на фото/телеизображении. В работе исследованы локальные методы выделения перепадов яркости и

методы активного контура. Выделенные границы объектов в дальнейшем используются для автоматического нахождения и распознавания объектов, представленных на изображении.

Характерной особенностью развиваемого подхода является применение специальных наборов искусственных изображений, разработанных для тестирования различных свойств методов выделения границ.

Качество работы того или иного метода оценивается путём сравнения результатов работы метода на зашумлённом или размытом изображении с эталонным препаратом границ, который формируется редактором тестовых изображений. В качестве шумов рассмотрены белый и гауссов, как наиболее адекватные при моделировании шумовых искажений.

Набор тестовых изображений [1] (рис. 1), обладает, по нашему мнению, свойством определенной полноты, то есть он охватывает значительное количество ситуаций, возникающих при обработке реальных изображений.

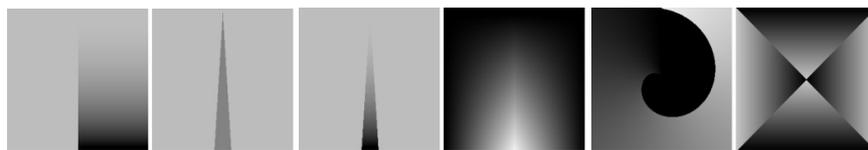


Рис 1. Слева направо: Вырождающаяся ступенька, Хребет, Вырождающийся хребет, Исчезающий излом, Улитка, Узел

Пусть идеальная граница состоит из N_t точек, и некоторый детектор границ при обработке изображения выделил N_d точек границы, из которых N_{td} точек выделены верно. Качество работы детектора границ оценивается параметрами: *чувствительность* = N_{td} / N_t , и *специфичность* = N_{td} / N_d . Чувствительность показывает, какая часть истинных точек границы найдена, а специфичность - какова доля истинных точек среди всех найденных.

Рассмотрены результаты тестирования шести известных [2] методов:

- Canny: классический алгоритм на основе линейного фильтра;
- Rothwell: динамический выбор порога и затем уточнение границы;
- Heitger: использование энергетического фильтра;
- Black: робастная анизотропная диффузия с итеративным сглаживанием;
- Smith: нелинейная фильтрация для поиска связанных частей изображения;
- Iverson: логические операторы для проверки существования границы.

Установлено, что все алгоритмы имеют хорошую чувствительность, то есть практически не теряют истинных граничных точек и заметно лучше справляются с белым шумом, чем с размыванием границ. Алгоритмы Canny и Rothwell обладают наилучшей специфичностью, то есть дают меньше ложных точек; остальные показывают примерно равные результаты.

При увеличении уровня белого шума, алгоритм Heitger имеет хорошую специфичность; алгоритм Black - удовлетворительную на изображениях "Хребет" и "Узел". Алгоритм Smith показывает очень хорошую специфичность на изображении "Хребет". Алгоритм Iverson на всех изображениях имеет невысокую специфичность.

Как оказалось, изображение "Исчезающий излом" является наиболее трудным для всех алгоритмов – ни один из них практически не выделил его границу. Изображение "Вырождающийся хребет" является более трудным, чем "Хребет". "Улитка" и "Узел" лучше обрабатываются всеми методами, по нашему мнению, потому что они имеют больший контраст вдоль границ.

После того, как на изображении выделены границы, они могут быть уточнены с помощью методов активного контура.

Активные контуры, или змейки, широко используются в задачах, связанных с сегментацией изображений [3] и выделением границ. В основе модели активного контура лежит параметризованная подвижная кривая на плоскости изображения. Каждому положению кривой соответствует значение функционала "энергии". Функционал определен так, чтобы кривая с минимальной энергией приближала границу определенного объекта.

При поиске результирующей граничной кривой используется метод динамического программирования для непосредственной минимизации энергии путем перебора положений кривой [4], без решения уравнений вариационной задачи. Тем самым исключается такой потенциальный источник ошибок, как вычисление производных высокого порядка.

Качество работы методов активного контура снижается при зашумлении изображения, а также при наличии на изображении участков границ с большой кривизной. Уровень шума можно уменьшить посредством традиционных фильтров, либо с помощью энергетических методов восстановления изображения [5]. Для исследования точности решения в зависимости от кривизны границ, разработано семейство искусственных изображений. На рис. 2 приведен набор объектов на основе окружности, на которую наложены две впадины и два выступа, размером от 0 до $0.8R$, где R - радиус окружности. При этом последовательно увеличивается кривизна.

Тестируемое изображение состоит из зашумленного фона и наложенных на него объектов. В качестве начального приближения используется истинный контур объекта, на который накладывается комбинация случайного и систематического искажения. Далее контур, найденный в ходе решения, наносится на изображение. По значениям в его пикселах определяется среднее E_{mean} и максимальное E_{max} расстояние до пикселей истинного контура. Эти две характеристики позволяют судить о точности решения в зависимости от значения кривизны и зашумления изображения.

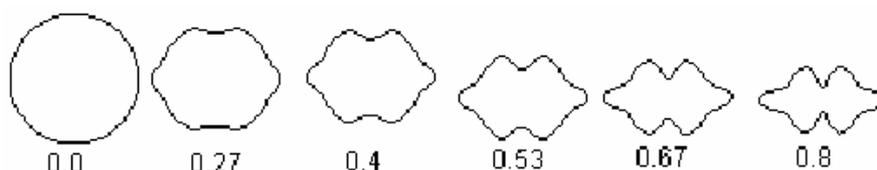


Рис. 2. Ряд объектов с изменением размера выступов и впадин.

Как правило, энергетические функционалы включают в себя параметры, позволяющие в значительной степени регулировать свойства функционала. Подбор этих параметров по минимуму величин E_{mean} и E_{max} позволяет существенно оптимизировать конкретный функционал.

Результаты экспериментов позволяют ставить в дальнейшем задачу построения помехоустойчивой адаптивной системы выделения границ объектов, учитывающей реальные характеристики изображения и в соответствии с ними выбирающие тот, или иной метод.

Литература

1. I.V.Gribkov, P.P.Koltsov, N.V.Kotovich, A.A.Kravchenko, A.S.Kutsaev, V.K.Nikolaev, A.V.Zakharov. PICASSO - Edge Detectors Evaluating System Based on the Comprehensive Set of Artificial Images. Proc. 6th World Multiconference on Systemics, Cybernetics and Informatics, Vol. 9, pp 88-93.
2. http://marathon.csee.usf.edu/edge/edgecompare_main.html *Edge Detector Performance. Evaluation Study @ USF.*
3. J.Park, J.J.M.Keller. Snakes on the Watershed. IEEE Trans. Pattern Analysis and Machine Intelligence, Vol 23, No 10, pp. 1201-1205, 2001.
4. A.A.Amini, T.E.Weimouth, R.C.Jain. Using Dynamic Programming for Solving Variational Problems in Vision. IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 12, No 9, pp. 855-867, 1990.
5. G.A.Hewer, C.Kenney, and B.S.Manjunath: Variational Image Segmentation Using Boundary Functions. IEEE Trans. Image Processing, v.7, No. 9, 1998, pp.1269-1282

Телевизионный датчик системы управления движением

В.А. Гришин
(Москва)

Задачи управления стыковкой (посадкой) являются классическими задачами управления движением. В ряде случаев ручной режим управления этим процессом труднореализуем. Проблема в том, что как элемент системы управления, человек обладает неудовлетворительными характеристиками, в частности по точности и быстродействию. Особенно трудно обеспечить необходимое качество ручного управления в случае большой массы объекта и/или большой скорости его движения перед началом выполнения маневра.

Для решения задач управления необходимо располагать информацией о пространственном и угловом положении объекта относительно заданного положения. Получить такую информацию можно, в частности, с помощью системы технического зрения (СТЗ), визирующей специальный стыковочный (посадочный) знак. Стыковочный знак представляет из себя совокупность пяти маркеров (оптически контрастных меток), как это показано на рис. 1. Линии, соединяющие маркеры, проведены только для облегчения восприятия и на самом стыковочном знаке отсутствуют.

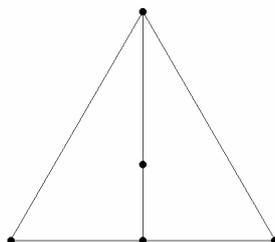


Рис. 1. Геометрия стыковочного знака.

На параметры СТЗ существенное влияние оказывает характер среды распространения светового излучения. Поглощение света, обратное рассеяние, наличие ярких перемещающихся посторонних объектов в поле зрения телевизионной камеры влияют как на величину максимального расстояния, на котором СТЗ способна функционировать, так и на устойчивость ее работы.

В работе рассматриваются алгоритмы обработки информации в СТЗ. Вопросы оптимизации конструктивной и схмотехнической реализации СТЗ, а также задача синтеза оптимальной структуры стыковочного знака требуют отдельного рассмотрения.

Программа обработки видеоинформации работает в двух основных режимах:

- режим поиска стыковочного знака;
- режим слежения за стыковочным знаком.

В режиме поиска стыковочного знака программа осуществляет поиск маркеров, образующих конфигурацию стыковочного знака, их обнаружение и распознавание. Координаты объектов, которые попали в поле зрения телекамеры и были распознаны как маркеры, заносятся в специальный список. Если количество объектов в списке больше или равно пяти, то генерируется множество гипотез о принадлежности каждого из обнаруженных объектов к стыковочному знаку (i -й маркер стыковочного знака, $i = 1..5$) или к иным объектам, находящимся в поле зрения. Для каждой гипотезы проверяется выполнение геометрических соотношений, характерных для стыковочного знака. Поиск осуществляется на

последовательности кадров изображений, поступающих от телевизионной камеры. Как только стыковочный знак обнаружен, программа переключается в режим слежения.

В режиме слежения поиск маркеров осуществляется уже в значительно меньшей окрестности положения каждого маркера на предыдущем кадре. Размер окрестности определяется динамикой углового и линейного движения объекта, а также периодом следования кадров изображения. Значительное уменьшение окрестности, в которой осуществляется поиск, обеспечивает существенное сокращение затрат времени на поиск. Длина списка обнаруженных объектов также значительно сокращается, что обеспечивает многократное уменьшение затрат времени на генерацию и проверку гипотез. Если в течение определенного количества последовательных кадров (зависящего от динамики объекта), стыковочный знак не обнаруживается, то такая ситуация классифицируется как сбой слежения и программа опять переключается в режим поиска.

При работе в режиме слежения координаты маркеров, образующих стыковочный знак, обрабатываются программой, формирующей оценки угловой ориентации стыковочного знака, расстояния до стыковочного знака, а также углов его визирования. Полученные оценки подвергаются фильтрации с целью уменьшения влияния случайных ошибок.

Для проверки функционирования алгоритмов было выполнено имитационное моделирование. Моделировалось распространение света с учетом поглощения и обратного рассеяния. Критичными параметрами является время, необходимое для поиска стыковочного знака, время обработки одного кадра изображения в режиме слежения и точность получаемых оценок линейных и угловых координат.

В табл. 1 приведены затраты времени в секундах на поиск стыковочного знака в зависимости от количества объектов, обнаруженных в поле зрения. Размер изображения - 512 на 512 пикселей. Моделирование производилось на ПЭВМ с процессором Celeron 1200.

Таблица 1. Время поиска стыковочного знака.

Количество объектов	10	15	20	25	30	35
Среднее время поиска, с	0,04	0,055	0,1	0,23	0,5	1,04

Из таблицы следует, что при количестве обнаруженных в поле зрения объектов, превышающем 35, время поиска становится недопустимо большим. Уменьшить время поиска можно синтезом более совершенной структуры стыковочного знака и использованием более эффективных алгоритмов.

Среднее время обработки одного кадра изображения в режиме слежения равно 17 мс. В это время входит поиск и распознавание стыковочного знака,

а также оценивание координат и фильтрация полученных оценок. Таким образом, возможна обработка потока телевизионных кадров в реальном времени.

Точность получаемых оценок расстояния (для объектива с фокусным расстоянием, равным 3,6 мм) оказалось вполне достаточной - 1-3 мм. Точность оценок угловых координат стыковочного знака (по азимуту) не хуже 0,3°. Точность визирования стыковочного знака не хуже 0,2°. С учетом поглощения и рассеяния света средой распространения стыковочный знак обнаруживался с расстояния в 2-3 метра. При реализации СТЗ основным источником погрешностей будет являться оптическая система, т.к. широкоугольные объективы характеризуются сравнительно большим уровнем геометрических искажений.

Таким образом, СТЗ может быть использована как датчик информации в задачах управления движением.

Литература

1. Системы технического зрения // Машиностроение. Ленингр. Отд-ние. Л., 1988.
2. Хорн Б.К.П. Зрение роботов (пер. с англ.) // Мир. М., 1989.
3. Грибов М.Г., Хачумов В.М. Определение геометрических параметров объектов по растровым изображениям // Автометрия. 2001. № 1. С. 40-49.
4. Гришин В.А. Монокулярный измеритель дальности и ориентации поверхности // Сб. научн. тр. Искусственный интеллект в технических системах. Вып. № 21, Гос. ИФТП. М., 2000. С. 47-55.

Формирование словаря для языка сокращенного описания программного кода

С.Д. Двоенко, В.Н. Абаджеев

(Тула)

Современная парадигма программирования требует документирования программного кода, что обычно реализуется в виде файлов помощи (help-файлов). Представляется целесообразным создавать файлы помощи на основе анализа описания структуры исходного программного кода на некотором специально приспособленном для этого языке. Создание такого языка следует рассматривать как распространение лингвистического подхода на анализ текстов программ, представляющих собой специфический вид данных [1].

В настоящее время наиболее распространены два типа систем документирования программного кода: системы, реализующие методы Reverse Engineering, и системы, реализующие методы Literate Programming. В первом случае по исходному программному коду генерируется его

подробное описание вплоть до построения графической схемы программы [2], во втором – при написании кода в него сразу необходимо вставлять комментарии в заранее определенном формате [3]. Недостатком в первом случае является то, что необходимо быть достаточно опытным пользователем соответствующей системы, а во втором – необходимо знать специальный язык составления комментариев и затратить время на их написание.

Поэтому актуальной является задача автоматического построения описания программного кода, которое скрывает несущественные детали синтаксиса конкретного языка программирования и описывает фразами, приближенными к естественному (например, английскому) языку, программные элементы и выполняемые над ними действия.

Программный код, рассмотренный как символьная последовательность, обладает четко выраженными признаками, которые позволяют однозначно разбить такую символьную последовательность на характерные фрагменты. Очевидно, что такими базовыми признаками исходного программного кода являются ключевые слова, обозначающие основные управляющие структуры и программные объекты (циклы, условия, заголовки подпрограмм, блоки, отступы и т.д.). Обозначив необходимые базовые признаки символами подходящего алфавита, который удобно назвать базовым, нетрудно преобразовать исходный код программы в короткую символьную цепочку, которая будет состоять только из базовых символов, пропуская все остальные символы между ними. Назовем такую цепочку эталоном. Так как многие программные конструкции обладают вложенностью, то также выделим из полученного эталона все вложенные элементы в отдельные эталоны.

Такое преобразование позволяет сразу же обнаружить идентичность двух, например, внешне сильно различающихся фрагментов программного кода разной длины, даже написанных на разных языках, если они образованы одной и той же последовательностью символов базового алфавита. Очевидно, что совпадающие эталоны указывают, по крайней мере, на одинаковый тип преобразований, выполняемый данными программами. Поэтому эти программы могут быть отнесены к одному классу и, следовательно, получить одинаковое итоговое описание на естественном языке.

Отметим, что проблема сопоставления символьных цепочек и, в более общем случае, дискретных сигналов разной длительности хорошо известна. Это, например, задачи парного и мультиэлаймента в биоинформатике, для решения которых разработаны специальные алгоритмы типа FASTA [4,5], структурные и лингвистические методы распознавания образов [6], задачи распознавания речевых сигналов [7], задачи анализа структурных экспериментальных кривых и сигналов [8,9]. В целом, решение проблемы

сопоставления между собой цепочек или дискретных сигналов напрямую зависит от того, удастся ли найти элементы цепочек или фрагменты сигналов, которые следует сопоставлять. Если такие базовые элементы или фрагменты найдены, то сопоставляемые последовательности удастся привести к одной длине (произвести выравнивание), что, в итоге, можно интерпретировать как их помещение в некоторое общее признаковое пространство.

Очевидно, что в рассмотренной задаче построения описания программного кода задача сопоставления символьных цепочек вырождается в простейшую процедуру проверки на полное совпадение двух цепочек. Это означает, что программы, оформленные в соответствии с некоторым заданным стилем, порождают большое количество эталонов, многие из которых идентичны друг другу. Поэтому на этапе формирования эталонов необходимо отобрать некоторое достаточное число часто встречающихся эталонов, исходя, например, из требования, чтобы было построено описание заданного процента от объема исходного кода.

Формирование эталонов заканчивается их описанием на естественном языке, которое вручную выполняет эксперт, «обучая» систему построения описания. Здесь возможна настройка системы, когда эксперт указывает, какие описания он, например, не хочет строить, обозначая их пробелами. Очевидно, что весь процесс формирования эталонов направлен на получение разных описаний для разных эталонов. Тем не менее, может оказаться, что разным эталонам необходимо сопоставить одно описание. Это может быть, например, в случае, когда разные программисты придерживались разных стилей оформления программ. Более сложным является случай, когда оказывается, что одному эталону необходимо сопоставить разные описания. Это означает, что базовые признаки исходного кода оказались слишком грубыми, и необходимо ввести дополнительные признаки (разные типы циклов, типы перебираемых элементов, операторы присваивания и т.д.), чтобы более детально сканировать исходный код программы, или отказаться от таких эталонов.

В случае более детального сканирования кода программы разнообразие эталонов, вообще говоря, может значительно увеличиться. Именно в этом случае возникает необходимость в применении процедур сопоставления символьных цепочек эталонов и оценивания их схожести со всеми вытекающими последствиями.

Экспериментальная проверка 1500 фрагментов программного кода на языке Object Pascal привела к формированию 20 эталонных цепочек над базовым 11-символьным алфавитом, представляющих 20 разных классов структуры программного кода. Для распознавания было предъявлено 100 фрагментов кода, написанных на том же языке программирования и не участвовавших в формировании эталонов. По каждому фрагменту

программного кода была построена соответствующая последовательность символов базового алфавита и выделены все подпоследовательности, соответствующие встретившимся вложенным конструкциям. В итоге 96,78% полученных цепочек, содержащих от 5 до 36 символов, оказались полностью составленными из эталонных цепочек, построенных на этапе формирования эталонов.

Литература

1. Моттль В.В., Мучник И.Б. Лингвистический анализ экспериментальных кривых// ТИИЭР, №5, Т.69, 1979. С. 12-39.
2. *Time2HELP*. Digital Logikk AS, <http://www.time2help.com>
3. Knuth D.E., Levy S. *The CWEB System of Structured Documentation*. Version 3.0. 1994.
4. Pearson W.R. *Rapid and sensitive sequence comparison with FASTP and FASTA*// Methods in Enzymology, 1990, 183, 63–98.
5. Durbin, R., Eddy, S., Krogh, A., and G. Mitchison, *Biological sequence analysis: Probabilistic models of proteins and nucleic acids*, Cambridge Univ. Press, 1998.
6. Фу К. Структурные методы в распознавании образов. М.: Мир, 1977.
7. Винцок Т.К. Анализ, распознавание и интерпретация речевых сигналов. Киев: Наукова думка, 1987.
8. Браверман Э.М., Мучник И.Б. Структурные методы обработки данных. М.: Наука, 1983.
9. Dvoenko S.D., Mottl V.V., Muchnik I.B., Nikolsky M.N. *Pattern Recognition in Experimental Waveforms*// Pattern Recognition and Image Analysis, Vol.1, No.1, 1991, pp. 87–98.

Восстановление объекта из изображений его частей

А.О. Евдокимов, И.Л. Егوشина

(Йошкар-Ола)

Задача сборки изображения из частей в общем случае заключается в восстановлении из определенного количества разрозненных и хаотично перемешанных частей полного изображения исходного объекта. Очевидно, сформулированную задачу можно рассматривать как интеллектуальную задачу, решение которой при определенных начальных условиях (большое количество частей, составляющих исходное изображение, наличие одинаковых фрагментов контурных линий, отсутствие некоторых частей) вызывает затруднения даже у человека и требует значительных временных ресурсов. Тем не менее, после введения ряда ограничений на начальные условия и применения аппарата контурного анализа [1] можно автоматизировать процесс сборки за счет алгоритмического решения поставленной задачи.

Целью работы являлась отработка алгоритмов восстановления изображения. Условно можно выделить 6 этапов работы по сборке изображения:

1. формирование изображений частей объекта в машинном представлении;
2. определение геометрических размеров изображений;
3. нумерация изображений;
4. представление изображений частей в виде контура;
5. нахождение контуров изображений, имеющих общие фрагменты;
6. восстановление объекта.

Для моделирования алгоритмов восстановления целесообразно полагать, что части исходного изображения переведены в графический формат и пронумерованы, а так же выбрано необходимое масштабирование (каждой из частей поставлено в соответствие необходимое количество элементарных векторов (ЭВ), которые должен содержать контур каждой из частей исходного изображения).

На этапе восстановления полного изображения объекта можно рассматривать несколько алгоритмов. Первый алгоритм представляет класс алгоритмов “грубой силы”. Такой алгоритм не требует проведения предварительных вычислений, однако, для реализации нужны значительные вычислительные затраты.

Сущность алгоритма сводится к анализу контурных линий (разрезов) в имеющихся частях данного изображения и пошаговой сборке фигуры при сопоставлении с исходным изображением (эталоном). Таким образом, реализация алгоритма осуществляется простейшим перебором всех возможных вариантов сложения фрагментов исходного изображения. Для определения общих фрагментов предлагается использовать скалярное произведение кодов контуров сравниваемых частей исходного изображения. В общем случае длина кодов различных частей не одинакова, в то время как скалярное произведение можно вычислить только для векторов одинаковой размерности. Это препятствие можно обойти, предварительно выбирая из двух сравниваемых частей ту, длина кода которой минимальна l_{\min} . Зафиксировав l_{\min} будем последовательно выбирать из кода большей части выборку длиной l_{\min} . Именно по этой выборке вычисляется скалярное произведение

$$SC = \sum_{n=0}^{l_{\min}} \gamma_{l_{\max}} v_{l_{\min}}^* \cdot \quad (1)$$

Затем формируется новая выборка, сдвинутая на один ЭВ и т.д. После перебора всех возможных вариантов определяется максимум скалярного

произведения. Выборки, для которых получен максимум, считаются идентичными и используются для восстановления изображения.

Второй алгоритм можно отнести к классу алгоритмов последовательного приближения. Этот алгоритм также не требует проведения предварительных вычислений и обладает более высоким быстродействием. В этом алгоритме также последовательно анализируются по принципу “каждый с каждым” все части исходного изображения. Однако для определения одинаковых фрагментов контурных линий используется следующая методика: из кода контура каждой из сравниваемых частей Γ_A и V_B осуществляется выборки из n элементарных векторов, $n = 1, 2 \dots l$, где l - размерность кода контура меньшей части. Причем из контура Γ_A производится одна выборка γ_j^n , а из контура V_B осуществляется l/n выборок. Далее вычисляется скалярное произведение выборок γ_j^n и v_i^n по формуле

$$SC_{ji} = \sum_{k=0}^n (\gamma_j^n)_k \cdot (v_i^n)_k^* . \quad (2)$$

Также необходимо вычислить

$$SC = \sum_{k=0}^n (\gamma_j^n)_k \cdot (\gamma_j^n)_k^* . \quad (3)$$

При выполнении условия

$$SC = SC_{ji} \quad (4)$$

фиксируются значения i выборки v_i^n , после чего, производятся выборки из $n + 1$ ЭВ. Особенность алгоритма заключается в том, что для контура Γ_A ЭВ отбираются от начальной точки O , а для контура V_B точка O каждой выборки определяется зафиксированными значениями i . После получения выборок повторно вычисляется скалярные произведения SC_{ji} и SC , проверяется условие (4), фиксируются значения выборки и осуществляется новая выборка. Если в процессе вычисления не зафиксировано ни одного значения i , то начальная точка O вектора Γ_A сдвигается на один ЭВ и процедура повторяется изначально со значения

$n = 0$. Если же зафиксировано только одно значение i , значит можно полагать выборки, полученные на последнем шаге идентичными и их можно использовать для восстановления исходного изображения.

В представленной работе были рассмотрены подходы к решению задачи о сборке изображения из его. Показана, возможность использования теории контурного анализа для решения поставленной задачи. Также наглядно показано, что применение методов согласованной фильтрации позволяет производить выделение и идентификацию фрагментов частей изображения, а также выполнить восстановление исходного изображения.

Разработанные алгоритмы сборки изображения объекта из его частей не являются оптимальными, однако, обеспечивают достаточно устойчивую работу автоматизированной системы сборки изображений.

Работа выполнена при финансовой поддержке РФФИ, проект №01-01-00298

Литература

1. Введение в контурный анализ и его приложения к обработке изображений и сигналов/ Под. ред. Я.А. Фурмана. - М.: Физматлит, 2002.
2. В.И. Васильев Распознающие системы. Справочник., Наукова думка, 1983.
3. Егошина И.Л., Михайлов А.И., Фурман Я.А. Оценка степени сходства двух плоских форм// Автометрия, 1995. – № 4.–С.19–26.
4. Прэтт У. Цифровая обработка изображений. Кн.1-2. – М.: Мир, 1982.

Применение имитационного моделирования для оценки качества метрик в задачах анализа клиентских сред

А.Н. Ефимов

(Москва)

Анализ клиентских сред (АКС) является актуальным направлением интеллектуальной обработки данных (data mining) и имеет многочисленные приложения в экономике. Под клиентской средой понимается множество клиентов некоторой компании, совершающих акты выбора по отношению к услугам (товарам) данной компании. В современных компаниях действия клиентов протоколируются, что позволяет проводить всесторонний анализ клиентской среды.

Одной из важных задач АКС является прогнозирование предпочтений клиента с целью генерации направленной рекламы. Для её решения могут применяться методы, основанные на введении эвристических функций близости на множествах клиентов и услуг и последующем синтезе проблемно-ориентированных метрик [1]. Сложность данной задачи по сравнению с обычными задачами распознавания и прогнозирования

заключается в том, что для алгоритмов генерации направленной рекламы не существует четкого формального критерия качества, такого, как число ошибок на обучающей выборке. В этой ситуации одним из подходов к оценке качества и оптимизации алгоритмов является имитационное моделирование.

В проведенном исследовании имитационная модель клиентской среды строилась в три этапа.

На первом этапе производилась группировка услуг некоторой реальной компании. Сначала услуги разбивались на три ценовые группы – низкая, средняя, высокая. Далее каждая ценовая группа разделялась некоторым образом на подгруппы (кластеры).

На втором этапе создавались группы клиентов и отдельные клиенты. Модель каждой группы фактически представляла собой распределение вероятностей на кластерах услуг. Путем небольшого варьирования вероятностей кластеров внутри каждой группы генерировались отдельные клиенты. Тем самым достигалось априорное разбиение клиентской среды на группы клиентов, схожих по своим предпочтениям.

На третьем этапе в соответствии с некоторым параметризованным эвристическим распределением генерировалась псевдослучайная последовательность актов выбора клиентов по отношению к исходному набору услуг.

Результатом работы имитационной модели является протокол функционирования клиентской среды. Он может быть передан в качестве исходных данных алгоритму генерации направленной рекламы. Критерием качества алгоритма является частота попадания услуг, предлагаемых алгоритмом, в кластер услуг, предпочитаемых данным клиентом. Вычисление данного критерия и оптимизация по нему становится возможным благодаря тому, что в имитационной модели предпочтения клиентов известны априори.

Работа поддержана Российским фондом фундаментальных исследований (проект № 01-07-90242).

Литература

1. Рудаков К. В., Никитов Г. В. О структуре метрических технологий DataMining. Интеллектуализация обработки информации: Тезисы докл. Симферополь, 2002. С. 218–220.

Информационный мониторинг публикаций по нейросетевым исследованиям

В.М. Ефременкова, И.А. Жлябинкова, Ю.Г. Сметанин
(Москва)

Рост числа публикаций, постоянно появляющихся в базах данных, приводит к необходимости совершенствования методов информационного мониторинга. Цели мониторинга – определение областей наиболее активных исследований, оценка тенденций в различных областях исследований на основе анализа публикаций и совершенствование структуры баз данных. В данной статье предпринята попытка классификации публикаций в области нейронных сетей с целью выявления тенденций развития в данной области. Выбор этой области объясняется экспоненциальным, с периодом удвоения 1 – 2 года, ростом числа публикаций, научных конференций и новых журналов, а также частоты встречаемости в библиографических базах данных ключевых слов типа «нейронные сети», «нейрокомпьютеры» и цитирований основных авторов этого направления. Предложенная методика мониторинга пригодна для других предметных областей.

Область исследований, получившая к настоящему времени устойчивое название «нейросетевые исследования», сформировалась в последние два десятилетия. Основные цели исследований в области искусственных нейронных сетей связаны с надеждой на создание эффективных средств для имитационного моделирования отдельных функций человеческого мозга, попыткой реализации возможностей ассоциативного мышления в системах распознавания образов, управления и оптимизации и исследованием предельного случая массового параллелизма при очень большом числе простых процессоров, когда программирование становится громоздкой задачей и целесообразно найти средства «самопрограммирования».

Преимущества нейронных сетей проявляются в тех задачах, где трудно выделять правила и велика размерность объектов, зато можно выбирать много обучающих примеров. Недостатком современных нейронных сетей является отсутствие явных правил и объяснения причин принятого решения.

С 1982 г. по 1988 г. происходило взрывное нарастание исследовательской активности в данной области. Анализ динамики распределения потоков публикаций в базе данных (БД) ВИНТИ (Россия) и БД INSPEC (Великобритания) выявил экспоненциальный, с периодом удвоения 1 – 2 года, рост числа публикаций, ростом числа публикаций, научных конференций и новых журналов с 1979 г. по 1988 г., а также частоты встречаемости в библиографических базах данных ключевых слов типа «нейронные сети», «нейрокомпьютеры» и цитирований основных авторов этого направления в БД Science Citation Index (SCI). Доля публикаций по нейронным сетям в массиве документов по искусственному интеллекту с 1982 г. по 1988 г. составила 14.9%; а их количество в этот же период

времени возросло в 36 раз.

Методы мониторинга основаны на использовании вторичной информации, накопленной в БД INSPEC, Chemical Abstracts (CA), Science Citation Index (SCI) и ВИНТИ. Анализ документальных информационных потоков во всех БД был проведен с 1982 г. (времени опубликования первой работы по нейронным сетям) и по настоящее время. В ходе анализа были определены особенности поиска в каждой из БД. Анализ временной динамики публикаций показывает, что после периода экспоненциального роста в 1982 г. - 1995 г. наступил период стабилизации и даже некоторого спада количества публикаций, отмечаемого пока только в БД INSPEC. Наиболее полный массив статей из журналов, трудов конференций, книг имеется в политематической БД INSPEC. Патентная информация представлена только в двух из четырех выбранных для анализа БД – ВИНТИ и CAS. Наличие меньшего массива публикаций в политематической, но все же химической БД Chemical Abstracts связано с отражением публикаций по нейронным сетям, применяемым преимущественно для обработки экспериментальных данных. Первые публикации здесь появились лишь в 1986 г., когда нейросетевые исследования начали использоваться для работ прикладного характера.

Начиная с 1995 г. потоки публикаций по нейронным сетям и нейрокомпьютерам практически сравнялись и составляют около 50.5% и 48.6% в общем массиве публикаций. Доля работ, относящихся к разработке элементной базы, составляет около 4.2%; к системам контроля нейроустройств – около 7.8%; к разработке оптических нейросетевых устройств - 1.7% публикаций, а по применению в биологии и медицине – около 22.4%; 26.1% публикаций содержат несколько аспектов исследования.

Основной поток первоисточников в БД ВИНТИ и CAS, характеризующий устойчиво развивающееся приоритетное направление, связанное с нейросетевыми исследованиями, состоит в основном из статей из периодических и продолжающихся изданий – около 84%, из которых около 1% приходится на публикации обзорного характера; статей из сборников трудов конференций – около 8%; книг и препринтов – около 1%; диссертаций – около 2%. Доля патентных документов составляет около 3%, отчетов – около 1.5%. БД INSPEC в качестве основных первоисточников для данного тематического направления рассматривает статьи из журналов – около 53.1%; статьи в трудах конференций – около 44.9%, причем еще около 9% статей, представленных на конференциях публикуется в профильных журналах; около 0.8% составляют книги и около 1.2% сообщения о конференциях, рефераты и отчеты. В БД SCI отражаются в основном статьи из журналов; даже труды конференций присутствуют в информационном массиве в основном в том случае, если они публикуются в одном из профильных по тематике конференции журнале.

Статьи из периодических и продолжающихся изданий в БД INSPEC, SCI, CAS и ВИНТИ 2001 г. представлены массивом около 1000 журналов, из которых ядерными являются 22: Proceedings of the SPIE (USA), IEEE Transaction on Neural Networks (USA), Neural Networks (GB), Neurocomputing (Netherlands), Neural Computation (USA), International Journal of Neural Systems (Singapore), Transaction of the Institute of Electrical Engineers of Japan (JP), AIP Conference Proceedings American Institute of Physics (USA) Journal of Chemical Information and Computer Sciences (USA), Physical Review E (Statistical, Nonlinear and Soft Matter Physics) (USA), Control Theory & Application (China), Нейрокомпьютеры: разработка, применение (Россия), Ecological Modelling (Netherlands), IEEE Transaction on Systems, Man and Cybernetics A (Systems & Humans) (USA), Neural Network World (Czech. Republic), Pattern Recognition (UK), IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences (Japan), Neural Processing Letters (Netherlands), Information and Control (China), Neural Computation & Application (UK), Fuzzy sets and Systems (Netherlands), Доклады РАН (Россия).

Неоспоримым лидером по числу изданий в области нейронных сетей остаются США, однако в последнее время очень быстро увеличивается число публикаций в КНР и Великобритании. Почти все остальные издания сосредоточены в Нидерландах, Японии и Германии. Нидерланды являются центром публикации авторов из разных стран, а в Японии и Германии активно публикуются местные авторы. Активные исследования ведутся также в Италии, на Тайване, в Испании, Франции, Южной Корее, Австралии.

Области наиболее активных исследований по нейросетевым исследованиям, число публикаций в которых нарастает особенно быстро: нечеткие нейронные сети, выделение правил из обученных нейронных сетей, клеточные нейронные сети, самоорганизация. Общим для этих направлений является то, что они вызваны проявившимися на практике недостатками традиционных нейросетевых моделей, проявившимися в приложениях.

Явно проявляющаяся тенденция к сближению числа публикаций по нейронным сетям и нейроустройствам показывает, что нейронные сети перестают быть модной темой теоретических исследований и становятся областью разработки практических средств для решения прикладных задач.

Работа выполнена при частичной поддержке РФФИ, гранты 00-03-40142И и 01-01-00052.

Новые методы повышения точности математического анализа электропривода намоточных устройств для химических нитей

*А.П. Жабко, Д.Н. Клименко, **В.Г. Роот**, А.Л. Шапошников*
(Санкт-Петербург)

Основная задача математического анализа динамики различных приводных механизмов, в том числе электроприводов намоточных устройств, состоит в получении переходных процессов (интегрировании описывающих систем уравнений), включая и процессы в случае скачкообразного изменения управляющего воздействия.

В рассматриваемых электроприводах в качестве двигателей в основном используются синхронно-реактивные электродвигатели (СРД), отличающиеся некоторыми особенностями, затрудняющими их математический анализ.

Одна из особенностей состоит том, что система уравнений СРД не разрешена относительно старших производных. С целью исключения операций типа обращения матриц, являющихся возможным фактором появления недостаточной точности интегрирования, предлагается использовать метод задания формы решений. При этом задание формы решений осуществляется для всех переменных токов статора и ротора.

Вследствие того, что форма решений для токов задается в виде полиномов низких степеней на каждом шаге разбиения интервала интегрирования, результаты интегрирования получаются приближенными. Для повышения точности интегрирования применяются новые методы, которые рассматриваются в данном материале.

С другой стороны, достаточно удобным в реализации оказывается метод интегрирования динамической системы СРД в переменных, обозначающих не токи, а магнитные потокосцепления обмоток. Для исключения токов обмоток из системы уравнений, учитываются связи между всеми токами и всеми потокосцеплениями, являющиеся системой линейных неоднородных уравнений, из которых выражаются токи через магнитные потокосцепления.

Далее сравнивались результаты, получаемые интегрированием по методу задания формы решения с применением новых методов повышения точности динамики СРД (повышения точности интегрирования), с результатами интегрирования динамической системы СРД в переменных, обозначающих не токи, а магнитные потокосцепления. При этом сравнении между собой соответствующие показатели дали достаточно хорошее совпадение, что косвенно подтверждает работоспособность предложенного метода

Литература

1. Математическое моделирование динамики электрических машин переменного тока: Учеб. пособие /Под ред. В.А. Климова. –СПб.:Изд-во С-Петербургского университета. 1995. 380 с.

**Ноль-схема интегрирования, как аппарат для уточнения
решения при математическом моделировании
оборудования для производства химических нитей**

А.П. Жабко, В.А. Климов, В.Л. Литвинчук, Д.Н. Клименко

(Санкт-Петербург)

При математическом моделировании оборудования для производства химических нитей, в частности, электропривода намоточных устройств, получение решения достигается различными методами, причем, всегда желательно получить возможно более точное решение возможно более простым методом.

В данной работе рассматривается моделирование синхронно-реактивного двигателя (СРД) методом задания формы решения. Модель составлена на основе дифференциальных уравнений напряжений обмоток статора

$$\frac{d\Psi_a}{dt} + r i_a = u_a,$$

$$\frac{d\Psi_b}{dt} + r i_b = u_b,$$

$$\frac{d\Psi_c}{dt} + r i_c = u_c$$

и эквивалентных обмоток ротора

$$\frac{d\Psi_{rd}}{dt} + r_d i_{rd} = 0,$$

$$\frac{d\Psi_{rq}}{dt} + r_q i_{rq} = 0.$$

Трудность решения такой системы уравнений определяется, в первую очередь, тем, что токи обмоток зависят от большого числа параметров, в том числе и от взаимного влияния обмоток.

В качестве одного из вариантов решения рассматривается возможность задания формы решения с помощью ортогональных базисов. Для получения более точного решения желательно на предварительном этапе осуществить анализ возможностей различных базисов для использования наиболее оптимального из них. При этом создается база знаний о возможностях описания сложных кривых, имеющих: затухание, колебательность, постоянную составляющую, экспоненциальность и т.п., которые могут быть использованы в качестве критериев применимости для оптимизации того

или иного базиса. На основе такой базы выбирается оптимальный (или хотя бы имеющий необходимые возможности) базис.

Для получения решения предлагается использовать ноль-метод, суть которого в рассматриваемой задаче сводится к следующему. На основе матрицы, описывающей модель СРД, составляется матрица чувствительности критериев оптимизации, под которыми понимаются невязки, возникающие вследствие приближенности метода, к параметрам системы, в качестве которых используются токи обмоток статора i_a , i_b , i_c и ротора i_{rd} , i_{rq} , а также частота вращения вала ω . Определяется влияние каждого параметра на величины всех невязок. И далее, по шагам, осуществляется сведение невязок к нулю путем изменения значений токов в обмотках, причем уменьшение невязок на каждом шаге выполняется параллельно в одинаковом относительном выражении, что становится возможным благодаря предварительному нахождению чувствительности критериев к параметрам системы.

Литература

1. Математическое моделирование динамики электрических машин переменного тока: Учеб. пособие /Под ред. В.А. Климова. –СПб.:Изд-во С-Петербургского университета. 1995. 380 с.

Формирование признакового пространства свойств синтетических нитей на основе акустических сигналов их возбуждения

А.П. Жабко, Е.Г. Маежов, А.С. Донской, Р.Р. Саакян
(Санкт-Петербург, Благовещенск)

Современные задачи моделирования поведения синтетических нитей в динамике и определение на их основе динамических характеристик потребительских свойств нитей, при ультразвуковых исследованиях, предъявляют значительные требования к идентификации акустических параметров на высокочастотной многоучастковой испытательной (ВМИ) установке, причем на нить действует сила натяжения, обеспечиваемая подвесом. Это обстоятельство делает необходимым детальный анализ выходного сигнала в ультразвуковых исследованиях синтетических нитей, а не только рассмотрение изменения несущей частоты.

Таким образом, диагностирование свойств нити является трудноформализуемой задачей и не может быть осуществлено на коротком интервале времени. Поэтому при решении указанной задачи нужно пройти через все этапы создания предварительных рабочих информационных обобщений (РИО) [1].

Сказанное означает необходимость использования системного подхода при анализе трудноформализуемых технологических объектов. Системность

заключается в применении при исследовании указанных объектов различных, в том числе и классических методов моделирования с целью выявления качественно новых, более точно описывающих объект исследования, признаков. Применение должно сопровождаться развитием существующих методов и их адаптацией к конкретным объектам исследования. Применительно к задачам распознавания и прогнозирования готовой продукции, речь идет о дополнении ее признакового пространства свойств и показателей качества новыми признаками.

Первоначально представленная задача решалась в следующих направлениях [2]:

- в теоретическом моделировании динамики нити на ВМИ установке был использован вариант модели реальной нити, полученный путем внесения в уравнение идеальной нити нелинейных членов, связанных с учетом ее упругих и демпфирующих свойств;

- осуществлены конструктивное развитие и адаптация рекуррентной конечно-разностной схемы решения уравнения динамики нити по методу Д'Аламбера;

- показано, что в форме экспериментально наблюдаемой кривой имеет место пачковая форма колебаний, причем пачки характеризуются собственными длительностью и амплитудой, что было подтверждено численными расчетами;

- определено, что в форме экспериментально наблюдаемой кривой возникают колебания двойной частоты относительно частоты возбуждения, что также было подтверждено численными расчетами.

В работе, основываясь на ранних исследованиях в этой области [2], [3], специальным образом обращается внимание на субгармонические колебания (колебания сравнительно низкой частоты относительно частоты возбуждения).

Рассматривается структурный и спектральный анализ выходного высокочастотного сигнала ультразвукового исследования синтетических нитей, с учетом субгармонических сигналов относительно частоты возбуждения, как для простой модели (один участок), так и для сложной модели (с взаимодействием участков). Заметим, что существенное влияние на субгармонические сигналы привносит параметризация (т.е. общая по всей установке координата вдоль нити).

Для моделей дается детальное описание условий возникновения и взаимодействия субгармоник, а также разложения основного решения по субгармоникам. Для сложной модели учтены субгармонические сигналы, вносимые не только собственными частотами, но и параметризацией, что усложняет поиск решения.

Следует указать, что задаче синтеза алгоритмов упорядочения классификации и оценки свойств нити должна предшествовать задача

анализа, т.е. задача выявления значимых характерных признаков в форме выходного сигнала, снимаемого с высокочастотной испытательной установки.

В работе рассматривается решение указанной задачи компьютерным моделированием.

В данной области уже имеется определенный опыт и результаты. Разработан программный пакет имитации полного движения (колебаний) нити на высокочастотной установке.

При проведении численных экспериментов были обнаружены следующие характерные признаки динамики нитей:

- зависимость скорости прохождения звуковой волны по нити от частоты возбуждения, от коэффициента упругости и коэффициента демпфирования нити;

- вследствие скольжения нити на опорах, появление на выходе высокочастотного (относительно частоты возбуждения) колебательного процесса;

- в выходном сигнале сохраняется явно выраженная картина наличия первого полупериода колебаний как при пренебрежении скольжением нити на опорах, так и при его учете;

- в выходном сигнале появляются низкочастотные колебания по отношению к высокочастотным колебаниям (сигналы модуляции), связанные тоже со скольжением нити на опорах;

- зависимость выходного сигнала от расположения опор в пространстве относительно друг друга, что может характеризоваться расстоянием между опорами по осям декартовых координат.

Полученные результаты позволяют проводить идентификацию свойств нити на основе выходного сигнала ультразвуковой испытательной установки для синтетических нитей с учетом субгармонических составляющих.

Литература

1. Романов В.Е., Климов В.А. Общенаучные и специальные принципы в экспериментальном моделировании и в создании расчетных методологий для технологических, технических и организационных систем текстильной и легкой промышленности//Материалы юбилейной научно-технической конференции, (Санкт Петербургский государственный университет технологии и дизайна). - СПб. – 2000. С. 102
2. Саакян Р.Р. Развитие основ методологического обеспечения ультразвуковых методов определения свойств синтетических нитей. Диссертация на соискание ученой степени кандидата технических наук. - СПб.: - 1994. - 257 с.
3. Саакян Р.Р. Системный анализ трудноформализуемых непрерывнозначных технологических задач. Диссертация на

соискание ученой степени доктора технических наук. - Благовещенск:
- 2002. - 260 с.

Конформная стеганография звукового сигнала в звуковом сигнале

А.А. Жарких
(Мурманск)

Введение

Цель данного сообщения – представление некоторых аспектов теории конформной защиты аналоговых сигналов и иллюстрация ее применения на примере конформной стеганографии звукового сигнала в звуковом сигнале.

Традиционно защита аналогового сигнала осуществляется с помощью скремблирования во временной или частотной области. При этом, как принято в традиционной криптографии, сам факт передачи сообщения не скрывается [1].

Стеганография представляет собой метод защиты информации, при котором сам факт ее передачи скрывается. Как правило, это осуществляется путем присоединения передаваемого сообщения к некоторому другому сообщению, называемому контейнером. Существующие методы стеганографии основаны на традиционных разделах анализа и дискретной математики [2,3]. В данном сообщении предлагается стеганографический метод защиты звукового сигнала, основанный на свойствах топологической группы конформных преобразований единичного круга в себя [4,5].

Любые аналоговые сигналы, такие как звук, изображение, геофизические данные и т.п., характеризуются конечными диапазонами изменения параметров - амплитуды, частоты, фазы. При подходящих сдвиге начала отсчета и нормировке, можно считать, что область изменения ограниченного сверху и снизу параметра представляет собой интервал $(-1,1)$, а для комплексного параметра, ограниченного по модулю – открытый единичный круг на комплексной плоскости. Важно отметить, что современная техника позволяет сделать такие преобразования сдвига и нормировки, также как и обратные к ним.

Остановимся подробнее на варианте звукового сигнала – типичном представителе одномерных вещественных сигналов. Считаем далее, что его значения нормированы и лежат в интервале $(-1;1)$.

Математическое обоснование

Для упрощения записи выражений введем обозначения «конформной арифметики». Сумма двух чисел из интервала $(-1;1)$ определяется выражениями (1) и (2). Произведение вещественного числа на число из интервала $(-1;1)$ со значениями в интервале $(-1;1)$ определяется выражениями (3) и (4).

$$\oplus : (-1;1)^2 \Rightarrow (-1;1) \quad (1)$$

$$\forall X, Y \in (-1;1) \quad Z = X \oplus Y = \frac{X+Y}{1+XY} \in (-1;1) \quad (2)$$

$$\otimes : (-1;1) \times (-\infty;+\infty) \Rightarrow (-1;1) \quad (3)$$

$$\forall X \in (-1;1) \& \forall r \in (-\infty;+\infty)$$

$$Z = X \otimes r = \frac{(1+X)^r - (1-X)^r}{(1+X)^r + (1-X)^r} \in (-1;1) \quad (4)$$

Обозначим через $X_{\hat{E}}(t)$ и $X_{\hat{N}}(t)$ сообщение- контейнер и скрываемое сообщения соответственно. Здесь традиционно через t обозначается время.

Определим алгоритм формирования стеганоосообщения следующей формулой:

$$S(\alpha, m, t) = X_{\hat{E}}(t) \oplus \left(X_{\hat{N}}\left(\frac{t}{m}\right) \otimes \alpha \right), \quad (5)$$

где α - параметр преднамеренного ослабления, m - параметр преднамеренного растяжения сигнала во времени.

Стеганосообщение, т.е. сообщение-контейнер с присоединенным передаваемым сообщением, передается через канал, в котором могут появиться ошибки $N_{\hat{E}}(t)$. После прохождения через канал стеганосообщение преобразуется следующим образом:

$$U_{\hat{E}}(\alpha, m, t) = S(\alpha, m, t) * N_{\hat{E}}(t), \quad (6)$$

где $*$ - операция взаимодействия сообщения и помехи в канале передачи.

Мы не моделируем изменение стеганосообщения в канале передачи. Мы отражаем только тот факт, что ошибки существуют, но являются достаточно малыми.

Алгоритм выделения скрытого сообщения из стеганосообщения можно представить следующими формулами

$$D_1(t) = U_{\hat{E}}(\alpha, m, t) \oplus (X_{\hat{E}}(t) \otimes (-1)), \quad (7)$$

$$D_2(t) = D_1(t) \otimes \frac{1}{\alpha}, \quad (8)$$

$$D(\alpha, m, t) = D_2(mt). \quad (9)$$

В предположении малости канальных ошибок, $D(\alpha, m, t)$ практически

совпадает с $X_{\hat{N}}(t)$. Если каналные ошибки не являются малыми, то выражение (9) должно быть изменено с учетом возможной компенсации этих ошибок

Заключение

Рассмотренные в данном сообщении математические основы частично анонсировались в докладах [6-8].

Предлагаемый стеганографический метод имеет ряд существенных достоинств. Он легко реализуем в реальном времени, свободен от эффекта переполнения в «конформной арифметике», его преобразования обратимы с высокой степенью точности. Основным его недостатком является нестойкость по отношению к атакам криптоаналитика владеющего частичной информацией о сообщении-контейнере.

Литература

1. Лагутин В.С., Петраков А.В. Утечка и защита информации в телефонных каналах, М.: Энергоатомиздат, 1996, 304 с
2. Молдовян А.А. и др. Криптография/ Молдовян А.А., Молдовян Н.А., Советов Б.Я.- Спб.: Лань, 2000.- 224 с.
3. Левин М. Криптография: Руководство пользователя/ М. Левин. – М.: Познавательная книга плюс, 2001.-264 с.
4. Лаврентьев М. А. , Шабат Б. В. Методы теории функций комплексного переменного. -М.: Наука, 1987, 688 с.
5. Кириллов А. А. Элементы теории представлений/ М.: Наука, 1978, 343 с.
6. Жарких А.А. Конформное преобразование формы сигнала для защиты аналоговых сообщений// Международная научно – техническая конференция Калининградского ГТУ.- Калининград: КГТУ, 1999, Сборник тезисов и докладов, ч. 4, с. 123.
7. Жарких А.А. Система шифрования с бегущим ключом// VI – я Международная конференция «Радиолокация, навигация, связь».- Воронеж: ВГУ – ВНИИС, 1999, Тезисы докладов, Т.3 , стр. 1886-1894.
8. Жарких А.А., Проблемы криптоанализа как проблемы распознавания образов// X – я Всероссийская конференция «Математические методы распознавания образов» (ВЦ РАН) , 2001, Сборник докладов, с. 209-212.

Распознавание звуковых сигналов на основе конформного анализа

А.А. Жарких
(Мурманск)

Введение

Цель данного сообщения – представление некоторых аспектов теории конформного анализа одномерных аналоговых сигналов и обсуждение возможности ее применения для распознавания звуковых сигналов.

Считаем далее, что значения звуковых сигналов нормированы и лежат в интервале $(-1;1)$.

В данном сообщении предлагается использовать для распознавания звуковых сигналов дифференциальное и интегральное исчисление, функциональный анализ и корреляционный анализ, основанные на конформных операциях сложения и умножения отличных от операций сложения и умножения поля вещественных чисел.

«Конформный» математический анализ в интервале $(-1;1)$

Для упрощения записи выражений, введем обозначения «конформной арифметики». Сумма двух чисел из интервала $(-1;1)$ определяется выражением (1). Произведение вещественного числа на число из интервала $(-1;1)$ со значениями в интервале $(-1;1)$ определяется выражением (2).

$$\forall X, Y \in (-1;1) \quad Z = X \oplus Y = \frac{X + Y}{1 + XY} \in (-1;1) \quad (1)$$

$$\forall X \in (-1;1) \& \forall r \in (-\infty; +\infty)$$

$$Z = X \otimes r = \frac{(1 + X)^r - (1 - X)^r}{(1 + X)^r + (1 - X)^r} \in (-1;1) \quad (2)$$

Обозначим через $X(t), Y(t)$ некоторые функции времени $t \in (-\infty; +\infty)$ со значениями в интервале $(-1;1)$. На основе операций (1)-(2) и традиционных предельных схем определения производной и первообразной были получены конформная производная $D(Y(t))$ (3) и конформная первообразная $I(Y(t))$ (4).

$$D(Y(t)) = \tanh\left(\frac{1}{1 - Y^2(t)} \frac{dY(t)}{dt}\right) \quad (3)$$

$$I(Y(t)) = \tanh\left(\frac{1}{2} \int \ln\left(\frac{1+Y(t)}{1-Y(t)}\right) dt\right) \oplus C \quad (4)$$

Производная и интеграл, стоящие под знаком гиперболического тангенса, понимаются в обычном смысле математического анализа функции вещественной переменной.

На основе выражения (4) был корректно определен конформный определенный интеграл (5).

$$\int_a^b Y(t) \otimes dt = \tanh\left(\frac{1}{2} \int_a^b \ln\left(\frac{1+Y(t)}{1-Y(t)}\right) dt\right) \quad (5)$$

Традиционный функциональный анализ предлагает для сравнения сигналов норму, метрику и скалярное произведение.

В «конформном анализе» такие характеристики, корректно связанные с характеристиками евклидова пространства, определяются следующим образом.

Норма определяется выражением (6)

$$\|X\| = \tanh\left(\frac{1}{2} \sqrt{\int_{-\infty}^{+\infty} \ln^2\left(\frac{1+X(t)}{1-X(t)}\right) dt}\right). \quad (6)$$

Метрика, ассоциированная с такой нормой, выражением (7)

$$\rho(X, Y) = \tanh\left(\frac{1}{2} \sqrt{\int_{-\infty}^{+\infty} \ln^2\left(\frac{1+X(t) \oplus Y(t) \otimes (-1)}{1-X(t) \oplus Y(t) \otimes (-1)}\right) dt}\right). \quad (7)$$

Связанное с нормой и метрикой скалярное произведение, определяется выражением (8)

$$(X, Y) = \tanh\left(\frac{1}{4} \int_{-\infty}^{+\infty} \ln\left(\frac{1+X(t)}{1-X(t)}\right) \ln\left(\frac{1+Y(t)}{1-Y(t)}\right) dt\right). \quad (8)$$

«Конформный» корреляционный анализ в интервале $(-1;1)$

Введенные таким образом понятия функционального анализа позволяют проводить адекватное сравнение сигналов принимающих значения в интервале $(-1;1)$ при их различных относительных сдвигах во времени.

Автокорреляционная функция любого такого сигнала может быть определена выражением (9)

$$K_{XX}(\tau) = \tanh\left(\frac{1}{4} \int_{-\infty}^{+\infty} \ln\left(\frac{1+X(t)}{1-X(t)}\right) \ln\left(\frac{1+X(t-\tau)}{1-X(t-\tau)}\right) dt\right). \quad (9)$$

Кросскорреляционная функция любой пары таких сигналов может быть определена выражением (10)

$$K_{XY}(\tau) = \tanh\left(\frac{1}{4} \int_{-\infty}^{+\infty} \ln\left(\frac{1+X(t)}{1-X(t)}\right) \ln\left(\frac{1+Y(t-\tau)}{1-Y(t-\tau)}\right) dt\right). \quad (10)$$

Заключение

В процессе эволюции органов слуха человека, появления речи и эволюции органов речи произошла адаптация этих органов.

Поэтому органы слуха работают в режиме насыщения приема звуковых сигналов, а органы речи - в режиме насыщения передачи звуковых сигналов. Эти режимы характеризуются некоторыми порогами насыщения. Подходящей математической функцией для описания режима насыщения является $\tanh(X)$.

Мы полагаем, что «конформный» математический анализ, является адекватным аппаратом для формирования и обработки речевых, музыкальных сигналов, а также звуковых сигналов произвольной природы, воспринимаемых ухом человека или животного.

В отличие от традиционного корреляционного анализа, «конформный» корреляционный анализ инвариантен относительно «конформного» усиления-ослабления определенного операцией умножения (2).

Предложенные в данном сообщении математические формулы дотошный исследователь может получить, ознакомившись с работами [1-3].

Литература

1. Лаврентьев М. А. , Шабат Б. В. Методы теории функций комплексного переменного. -М.: Наука, 1987, 688 с.
2. Кириллов А. А. Элементы теории представлений.- М.: Наука, 1978, 343 с.
3. Жарких А.А. Конформное преобразование формы сигнала для защиты аналоговых сообщений// Международная научно – техническая конференция Калининградского ГТУ.- Калининград: КГТУ, 1999, Сборник тезисов и докладов, ч. 4, с. 123.

Разработка универсальной программной системы интеллектуального анализа данных, распознавания и прогноза

*Ю.И. Журавлев, В.В. Рязанов, О.В. Сенько, А.С. Бирюков, Д.П. Ветров,
А.А. Докукин, Н.Н. Катериночкина, Д.А. Кропотков, А.С. Обухов,
М.Ю. Романов, И.В. Рязанов, Ф.Б. Челноков*
(Москва)

Введение

При обработке данных в медицине, экономике, социологии, физике, биологии часто возникают задачи распознавания, классификации, поиска зависимостей. При этом сами пользователи обычно не являются специалистами в теории распознавания и предпочитают пользоваться готовыми программными продуктами. Разработки подобных программных систем активно ведутся в России и ведущих зарубежных странах. Прежде всего, это весьма дорогие и консервативные статистические пакеты обработки данных и визуализации. Их недостатки – требование специальной подготовки пользователей и стандартные ограничения статистических моделей. В последние годы появились узкоспециализированные пакеты интеллектуального анализа данных. Для данных пакетов обычно характерна ориентация на узкий круг практических задач, а их алгоритмической основой является какая-либо одна из альтернативных моделей, использующая, нейронную сеть, решающие деревья, ограниченный перебор, и т.п. Ясно, что подобные разработки будут существенно ограничены при практическом использовании, поскольку заложенные в них подходы не являются универсальными относительно размерностей задач, типа данных, «степени компактности» классов, величины шума, противоречивости данных, и т.п. Данный факт подтверждает как сосуществование различных подходов для решения одних и тех же задач, так и опыт практического распознавания самих авторов.

В настоящей работе представлена первая версия универсальной программной системы интеллектуального анализа данных, распознавания и прогноза. В основу требований к системе положены идеи ее универсальности и интеллектуальности.

Под универсальностью системы понимается возможность ее применения к максимально широкому кругу задач (по размерностям, по типу, качеству и структуре данных, по вычисляемым величинам). Под интеллектуальностью понимается наличие элементов самонастройки и способности успешного автоматического решения задач неквалифицированным пользователем.

Для создания алгоритмического обеспечения исследования проводились по следующим направлениям: модификация различных подходов, развитие

средств решения задач распознавания и классификации коллективами алгоритмов, создание средств оценки надежности полученных решений.

Предполагалось, что программный продукт будет реализовывать следующие возможности: объединение в единой системе различных методов распознавания и классификации, построение коллективных решений на базе решений, построенных различными методами, современный графический интерфейс, унификация пользовательского интерфейса для различных методов, возможность визуального представления данных и результатов обучения, предоставление отчетов об обучении и распознавании в унифицированном удобном виде, возможность автоматического обучения, предоставление готовых сценариев обучения и методов контроля качества обучения, возможность дальнейшего расширения программного продукта без затрагивания уже созданных частей программы.

Описание структуры программы.

Программный продукт имеет следующую структуру (рис.1).

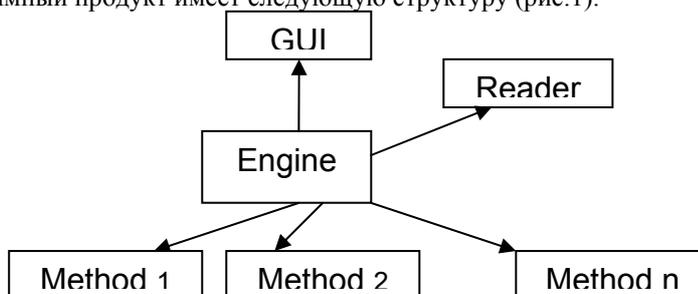


Рис. 1. Схема устройства программы (GUI – graphic user interface).

Весь программный продукт разбит на модули, которые реализуют разработанный и жестко зафиксированный интерфейс. Таким образом, существует возможность замены любого модуля без затрагивания остальных или добавление еще одного модуля методов.

Основным модулем программы является Engine, отвечающий за управление всеми процессами, происходящими в системе, и связь между модулями. Также в него вынесены все общие места различных модулей, что позволяет облегчить дальнейшую разработку библиотек методов. Конечному пользователю предоставляется возможность написания своих методов и присоединения их к системе без участия первоначальных разработчиков.

Каждый метод реализован в виде отдельной динамической библиотеки и может модернизироваться без затрагивания других частей программы. Различные математические методы и полезные утилиты собраны в отдельной общедоступной статической библиотеке. Реализована возможность одновременного вычисления несколькими методами. Данная

возможность позволяет распределять вычисления по сети в том случае, если библиотеки методов реализованы не в виде динамических библиотек, а в виде объектов DCOM.

Программная реализация.

В рамках программного продукта были реализованы следующие методы распознавания и классификации: «нейронная сеть», «тестовый алгоритм», «линейный дискриминант Фишера», «к ближайших соседей», «метод опорных векторов», «статистически взвешенные синдромы», «алгоритмы вычисления оценок», «логические закономерности», «итеративная оптимизация», «иерархическая группировка», «к внутригрупповых средних», «метод локальной оптимизации». Реализовано несколько различных методов построения коллективных решений для задач распознавания и классификации.

Основное рабочее окно программы показано на рисунке 2.

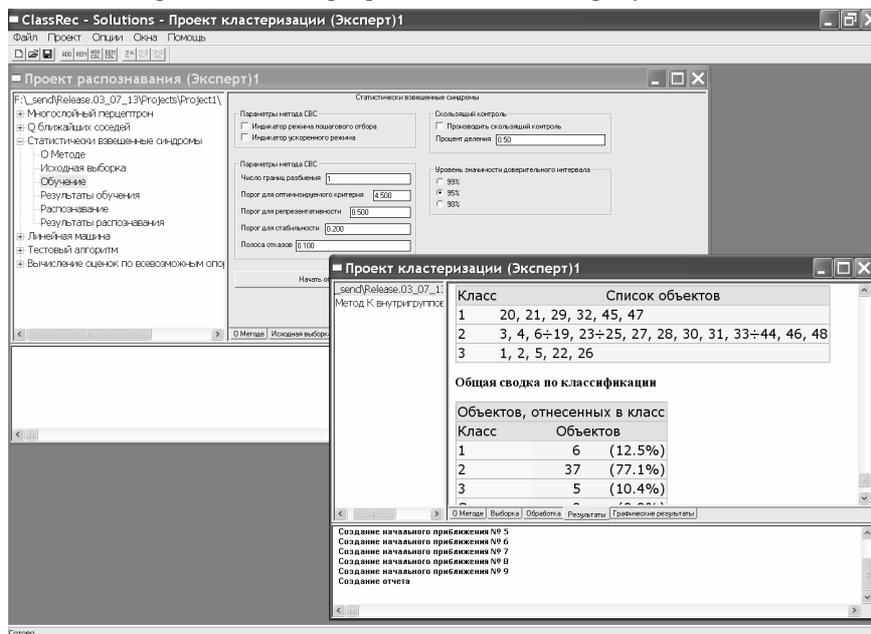


Рис. 2. Основное окно программы.

К настоящему времени система успешно апробирована на 20 модельных и реальных практических задачах.

Настоящая работа выполнена при поддержке Российского фонда фундаментальных исследований (проекты №02-01-08007, 02-01-00558, 02-07-90134, 02-07-90137, 03-01-00580), Программ №7, 17 фундаментальных исследований Президиума РАН, Фонда содействия развитию малых форм

предприятий в научно-технической сфере (договор №1680р/3566).

Описание молекулярных графов в задаче «структура-свойство» с использованием нечеткой логики.

А.М. Захаров, М.И. Кумсков, Л.А. Пономарева

(Москва)

Предложена новая схема описания молекулярных графов в виде таблицы «граф-признак» в задаче «структура-свойство». Вводятся дескрипторы, позволяющие описать структурные фрагменты, характеризующие взаимное расположение химических функциональных групп, с помощью нечеткой логики. Вводятся классы расстояний между элементарными фрагментами и оценивается степень принадлежности фрагмента графа к заданному классу расстояний. Достоинством предложенного описания является возможность корректно учитывать пространственные конформации гибких молекул.

Постановка задачи.

Пусть имеется база данных (БД) химических соединений, представляемых молекулярными графами [1], и для каждого соединения задано числовое значение исследуемого свойства. Требуется построить для каждого соединения описывающий его вектор, состоящий из переменных нечеткой логики. Полученная таблица «граф-признак» далее анализируется стандартными алгоритмами построения зависимостей.

Методы решения.

Выделим во всех молекулах из БД «особые точки» (элементы описания). Особыми точками могут служить атомы (помеченные вершины молекулярного графа), цепочки помеченных атомов, точки не связанные с атомами непосредственно и выбираемые в пространстве, окружающем молекулу [2]. Каждой «особой точке» присваивается символьная метка (тип точки). Каждая особая точка имеет координаты (планарные или пространственные), либо характеризуется областью пространства молекулы, в которой эта точка может находиться и вероятностью нахождения в этой области (такой способ задания особых точек необходим для представления гибких молекул).

Далее, пусть d_{\max} - максимум по всей выборке из всех возможных евклидовых расстояний (с учетом конформаций) между особыми точками одной молекулы из БД. Введем на отрезке $[0, d_{\max}]$ дискретизацию (N классов) расстояний (задающую нечеткие множества), и определим функции принадлежности $f_i(d), i = 1, \dots, N$ (например, можно ввести классы «малых», «больших» расстояний и т.д.).

Сформируем алфавит дескрипторов следующим образом: рассмотрим

внутри каждой молекулы из БД всевозможные пары особых точек. Пусть пара состоит из особых точек с метками T_1 и T_2 . Тогда она порождает N дескрипторов с именами (T_1, T_2, i) , где $i = 1, \dots, N$. Алфавит дескрипторов AD будет состоять из объединения всех имен, полученных таким образом.

Построим теперь для каждой молекулы описывающий ее вектор признаков в заданном таким образом алфавите дескрипторов. Для этого найдем численное значение каждого дескриптора из AD по следующей схеме: пусть дескриптор имеет имя (T_1, T_2, i) ; найдем в молекуле все пары особых точек с именами T_1 и T_2 . Пусть рассматриваемая пара состоит из точек, находящихся на расстоянии d друг от друга (в случае гибких молекул на отрезке $[0, d_{\max}]$ вычисляется плотность распределения $p(d)$, характеризующая вероятность нахождения особых точек на том или ином расстоянии). Тогда эта пара будет порождать значение дескриптора $f_i(d)$ в

«негибком» случае или $\int_0^{d_{\max}} f_i(t)p(t)dt$ в гибком случае. Окончательно,

выберем численное значение дескриптора равным максимальному или среднему из всех значений, порожденных таким образом.

Таким образом, для каждой молекулы формируется ее вектор признаков, состоящий из чисел из отрезка $[0,1]$. Эти числа характеризуют степень, с которой пара особых точек, соответствующая дескриптору из AD , «проявляется» в молекуле. В дальнейшем полученная матрица «граф-признак» может быть обработана каким-либо алгоритмом для построения количественных корреляций «структура-свойство» (например, методом группового учета аргументов, одним из методов поиска классифицирующих логических правил и т.д.). Предложенная схема позволяет преодолеть недостаток «жесткого» представления интервалов дискретизации расстояний при описании взаиморасположения ключевых химических функциональных групп. Предложенный подход может быть естественно обобщен для «нечеткого» описания троек и четверок особых точек.

Литература

1. Rouvray D.H. (Ed.) Computational Chemical Graph Theory. // New York, Nova Publ., 1989.
2. Kumskov M.I., Zyryanov I.L., Svitan'ko I.V. A New Method for Representing Spatial Electronic Structures of Molecules in the Problem of Structure-Biological Activity Relationship. // Pattern Recognition and Image Analysis, 1995, n.3, p.477-484.

Представление молекулярных графов «нечеткими треугольниками» при прогнозировании биологической активности.

А.М. Захаров, М.И. Кумсков, Л.А. Пономарева, Л.К. Маслова
(Москва)

Известной моделью биологической активности является пространственный треугольник, у которого вершины имеют заданные локальные физико-химические свойства, а стороны треугольника задаются интервалами расстояний. Если существует 3D-конформация молекулы, «содержащая» такой треугольник, то считается, что она будет обладать заданным биологическим свойством [1].

Будем определять принадлежность «гибкого» треугольника гибкой молекуле в терминах нечеткой логики. Для поиска таких «треугольных» моделей предлагается новая схема описания обучающей выборки в виде таблицы «молекула-признак» с использованием переменных нечеткой логики. Предлагаемый подход позволяет единообразно искать не только пространственные модели-«треугольники», но и 3D-пирамиды, где расстояния между вершинами задаются интервалами.

Постановка задачи

Пусть дана база данных (БД) химических соединений, представляемых молекулярными графами и для каждого из них известно, является ли оно биологически активным. Необходимо описать такие пространственные треугольники, наличие которых в молекуле влечет за собой ее активность.

На основании предварительно заданных правил в молекуле выделяются особые точки (базовые фрагменты), которые могут являться вершинами треугольников. Каждой точке присваивается символьная метка (тип точки), отражающее ее физико-химические свойства. Для каждой точки заданы либо ее координаты (планарные или пространственные), либо область пространства, в которой она может находиться и плотность, характеризующая вероятность появления точки в различных участках этой области.

Пусть d_{\max} - максимум по всей выборке из всех возможных евклидовых расстояний (с учетом конформаций) между особыми точками одной молекулы из БД. Введем на отрезке $[0, d_{\max}]$ некоторым образом N классов расстояний (нечетких множеств), задаваемых функциями принадлежности $f_i(d), i = 1, \dots, N$.

Сформируем всевозможные классы пространственных треугольников следующим образом: переберем внутри каждой молекулы из БД все тройки особых точек. Пусть тройка состоит из точек с метками T_1, T_2 и T_3

(необязательно различных). Тогда она порождает N^3 классов «нечетких треугольников» с именами $(T_1, T_2, T_3, i_1, i_2, i_3)$, где $i_1, i_2, i_3 = 1, \dots, N$. Перебрав таким образом все молекулы БД, получим список всех встречающихся в выборке классов треугольников.

Определим для каждой молекулы степень принадлежности ей нечеткого треугольника класса $(T_1, T_2, T_3, i_1, i_2, i_3)$. Найдем внутри молекулы все тройки особых точек (T_1, T_2, T_3) и обозначим d_1 расстояние между T_1 и T_2 , d_2 - расстояние между T_2 и T_3 , d_3 - расстояние между T_3 и T_1 (если в какой-то из пар одна или обе особые точки могут менять свое положение в пространстве за счет конформаций молекулы, то вычисляется соответствующая плотность распределения $p_m(d), m = 1, 2, 3$, характеризующая вероятность нахождения особых точек на заданном расстоянии друг от друга). Для класса треугольников $(T_1, T_2, T_3, i_1, i_2, i_3)$ эта тройка будет порождать три различных значения, характеризующих степень принадлежности сторон треугольника $T_1T_2T_3$ к введенным на отрезке $[0, d_{\max}]$ классам расстояний с номерами i_1, i_2, i_3 ; в случае «негибкого» треугольника эти значения вычисляются как $t_j = f_{i_j}(d_j)$, а затем конечное значение, характеризующее принадлежность треугольника к молекуле, вычисляется как $f(t_1, t_2, t_3)$, где f - минимум, максимум, среднее значение или произведение t_1, t_2, t_3 . В случае гибкого

треугольника степень принадлежности вычисляется как
$$\frac{\int_{\Omega} f(f_{i_1}(t_1), \dots, f_{i_3}(t_3)) p_1(t_1) p_2(t_2) p_3(t_3) dt_1 dt_2 dt_3}{\int_{\Omega} p_1(t_1) p_2(t_2) p_3(t_3) dt_1 dt_2 dt_3}$$
, где Ω - множество

таких троек t_1, t_2, t_3 , которые могут служить сторонами треугольника (т.е. для них выполняется неравенство треугольника).

Литература

1. Makeev G.M., Kumskov M.I., Svitan'ko I.V., Zyryanov I.L. Recognition of Spatial Molecular Shapes of Biologically Active Substances for Classification of Their Properties./ Pattern Recognition and Image Analysis, 1996, v.6, n.4. p.795-808.

Программный комплекс для решения задач классификации минералов на основе алгоритма обратного распространения ошибки

С.В. Зинченко, М.С. Хозяинов, О.А. Якушина
(Москва)

В последние годы для изучения внутренней микроструктуры минеральных образований все чаще используются неразрушающие методы анализа, наиболее перспективным из которых представляется метод рентгеновской томографии, имеющий значительно более высокую (на один – два порядка) по сравнению с обычной радиографией чувствительность к локальным неоднородностям в объекте. Необходимо лишь суметь проанализировать изображение томограммы, полученное в результате сканирования минерала [1].

Томограммы, получаемые при сканировании минералогических образцов, могут быть очень сложными. На таких изображениях получается несколько различных минеральных фаз; размеры зерен в пределах образца существенно колеблются. Часто наблюдаются сложные взаимоотношения между зернами (сложные текстуры), в то время как оптический контраст между различными минералами невелик. Поэтому многие минералогические изображения трудно поддаются анализу. Обычно минералог «описывал» эти сложные изображения как можно подробнее в качественных терминах. В настоящее время подобные описания не могут удовлетворить инженера-технолога, поскольку для разработки и контроля процессов переработки минералов ему необходима количественная информация. Неоднократно делались попытки упростить методы получения количественной информации относительно шлифов пород, и в настоящее время появилась возможность количественно характеризовать даже сложные изображения с помощью компьютерных автоматических систем анализа оптических изображений. Эти системы основаны на выделении микронеоднородностей по величине амплитуды измеряемого сигнала[2].

Описываемый программный комплекс предназначен для выявления однородных объектов изображения томограммы минеральных образований на основе метода распознавания образов. Полностью реализована многослойная нейронная сеть, обучаемая по алгоритму обратного распространения ошибки. Комплекс имеет в своем составе средства для конструирования, обучения и оценки нейросети.

На изображении томограммы минерального образования, заранее правильно разделенного на фазы (совокупность зерен одного минерала), выбираются области для обучения и области, содержащие те части изображения, которые необходимо распознать. На основе выбранных областей формируется два множества – обучающее и экзаменационное.

Далее необходимо оптимизировать архитектуру сети, остановившись на

варианте сети, который обеспечивает наилучшую способность к обобщению. Программа позволяет выбрать топологию сети, функцию активации нейронов, задать критерии остановки обучения [3].

Обучив нейронную сеть, можно проводить распознавание других томограмм, схожих по составу с образцом, на основе которого обучалась нейронная сеть. Результатом распознавания изображения являются фазы, каждая из которых представляет собой совокупность зерен одного минерала.

На рис. 1 представлено главное окно программы с двумя изображениями томограмм. Томограмма расположенная слева была проанализирована минералогами и была разбита на четыре фазы: родохразит 1 генерации (черная), родохразит 2 генерации (серая), слоистые алюмосиликаты (светло серая), опал (белая). На основе этого разбиения проводилась оптимизация архитектуры нейронной сети и ее обучение. Томограмма, расположенная справа была распознана нейронной сетью, что позволило выделить три фазы: родохразит 1 генерации (черная), родохразит 2 генерации (серая), опал (белая). Анализ процентного содержания фаз распознанной томограммы показал, что разбиение томограммы на фазы схоже с таким же разбиением, проделанным минералогами.

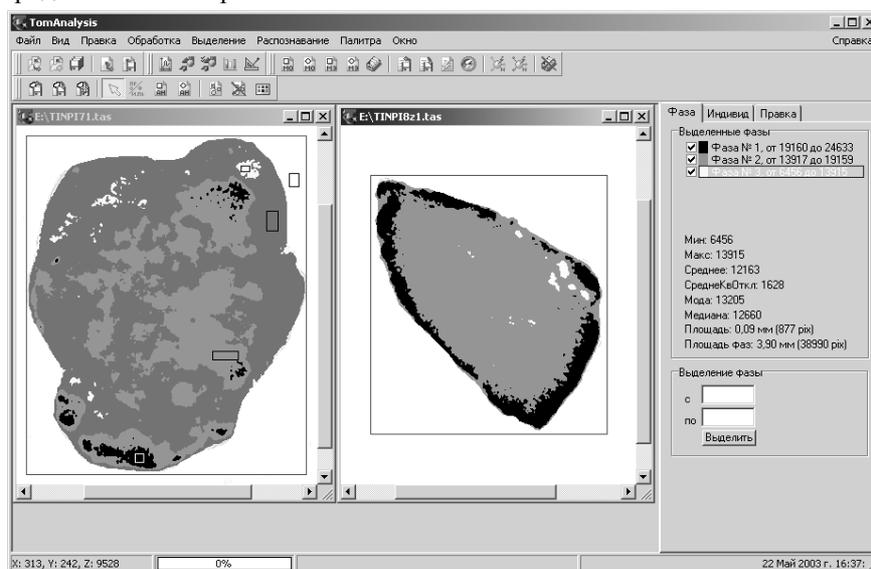


Рис. 1. Томограммы образцов карбонатных руд Тыннинского месторождения – осадочного происхождения.

Проведенное исследование показало, что для выделения совокупности зерен минерала на нескольких изображениях томограмм, достаточно обучить нейронную сеть на одной наиболее представительной томограмме и производить распознавание остальных томограмм.

Программный комплекс позволяет обрабатывать рентгеномтограммы для получения необходимых параметров образца и представлять их в виде таблиц или гистограмм. Параметры, получаемые в результате обработки, выбраны исходя из потребностей инженера-технолога и полностью удовлетворяет его запросы для разработки и контроля процессов переработки минералов. При создании автоматизированной системы использовались типовые решения, определенные требованиями различных технических инструкций, что позволило выполнить весь комплекс задач, направленных на реализацию информационных и управляющих функций. Такой подход позволил сократить время на разработку алгоритмов и математического обеспечения комплекса и обеспечил высокую надежность функционирования системы.

С помощью предлагаемого программного комплекса были обработаны данные рентгеномтографического исследования, выполненного на материале технологических проб карбонатной марганцевой руды (подобраны ВИМСом) Тынынского и Успенского месторождения (Урал), представленном кусками марганцевых руд разного типа (песчанистым, песчано-глинистым, кремнистым и конкреционно-глинистым).

Литература

1. Хозяинов М.С., Козорезов Е.В. Неразрушающий анализ структуры минеральных образований с использованием рентгеновского компьютерного микротомографа. М.: ВНИИГеосистем, 1996. 71с.
2. Зинченко С.В. Быстродействующая система анализа рентгеномтографических изображений // Геоинформатика. Москва, 2001. №4. С. 52-56.
3. www.basegroup.ru

Исследование основных краткосрочных экономических показателей РФ

Т.В. Казакова, В.В. Шакин
(Москва)

В настоящем докладе приводятся результаты анализа основных экономических показателей РФ. Исходные временные ряды представляют собой ежеквартальные данные за период с четвертого квартала 1994 г. по 2 квартал 2002 г. [1].

Для исследования структуры данных был выбран метод "Гусеница", или Singular Spectrum Analysis (описание метода можно найти в [2], [3]) по трем причинам. Во-первых, метод с успехом работает на коротких временных рядах. Во-вторых, многомерный вариант метода позволяет выделить общую для всех рядов закономерность в их поведении. В-третьих, метод не требует предварительной обработки данных несмотря на то, что исходные

временные ряды представлены в разных шкалах.

В результате анализа многомерных данных была выявлена общая для всех рядов сезонная составляющая (годовая периодичность). Ниже на рисунке представлен пример исходного ряда и восстановленного по сезонной составляющей.



Рис. 1. Экспорт товаров и его сезонная составляющая.

На основе компонент, отвечающих за годовую периодичность, исходные ряды были восстановлены и проанализированы. Для анализа был введен коэффициент сезонности, который отвечает за то, насколько сильно выражена периодичность на фоне исходного ряда, и представляет собой отношение среднего значения амплитуды колебаний к среднему значению тренда на интервале наблюдений, умноженное на 100. В качестве интервалов наблюдений были взяты два временных промежутка: с 4 квартала 1994 г. по 2 квартал 1998г. и с 1 квартала 1999 г. по 2 квартал 2002 г. Характер изменения данных в связи с дефолтом отражен в коэффициенте изменения, который определен как отношение среднего значения тренда после дефолта к среднему значению тренда до дефолта для каждой исследуемой величины. Полученные результаты представлены в виде таблицы.

По результатам анализа данных таблицы были выдвинуты следующие гипотезы:

- Характер колебаний обменного курса доллара не изменился, что подтверждается почти равными значениями коэффициента сезонности до и после дефолта. При этом коэффициент сезонности в колебаниях курса доллара за оба рассматриваемых периода незначителен.
- Кризис 1998 года не оказал существенного краткосрочного влияния на расходы по обслуживанию внешнего государственного долга. Это подтверждается тем, что изменение объема затрат в рублях

соответствует изменению курса доллара за рассматриваемый период. В то же время, анализируемые данные не дают возможности сделать вывод об отсутствии влияния кризиса на расходы по обслуживанию внешнего государственного долга в долгосрочной перспективе.

- Объем государственных социальных расходов изменился в существенно меньшей степени, чем курс доллара. Соответственно, даже с учетом снизившихся цен в долларовом эквиваленте, можно сделать вывод об уменьшении объема выполняемых государством социальных обязательств.
- Инвестиции в основной капитал увеличились после кризиса практически в той же пропорции, что и курс доллара, из чего можно сделать вывод о восстановлении инвестиционной привлекательности России в посткризисный период или даже о ее повышении (если учесть, что сразу после кризиса объем инвестиций значительно уменьшился). На основании полученных данных можно сделать вывод о ярко выраженной сезонной зависимости объема инвестиций (порядка 60%), имевшей место как до кризиса, так и после него. Пик сезонных колебаний приходится на 4 квартал.
- На основе результатов анализа данных можно сделать вывод о росте экспорта товаров в долларовом исчислении и о увеличении сезонной зависимости его объема.
- Анализ значения ВВП показал, что после кризиса сезонные колебания стали более выраженными, с увеличением коэффициента сезонности до 17%.
- Увеличение расходов домашних хозяйств после кризиса превысило увеличение доходов населения, что свидетельствует об ухудшении уровня жизни населения.

Работа поддержана Швейцарским научным фондом, грант № 7 IP 65730.

Литература

3. <http://www.cemi.rssi.ru>.
4. Данилов Д.Л., Жиглявский А.А. Главные компоненты временных рядов: метод "Гусеница"// СПбГУ, 1997. 308 с.
5. Milan Palus and Dagmar Novotna, Detecting modes with nontrivial dynamics embedded in colored noise: Enhanced Monte Carlo SSA and the case of climate oscillations// *Phys. Lett. A* 248, 1998. P. 191-202.

Ряд	Амплитуда колебаний		Тренд		Коэфф. изменения	Коэфф. сезонности		МАХ
	до дефолта	после дефолта	до дефолта	после дефолта		до дефолта	после дефолта	
E	0,134	0,699	5,138	27,891	5,428	2,614	2,506	1 квартал
GD	3,497	22,426	11,268	52,156	4,629	31,031	42,997	2 квартал
GT	42,397	46,682	143,425	280,32	1,954	29,557	16,654	2 и 4 кварталы
I	48,675	157,24	83,505	303,321	3,632	58,29	51,839	4 квартал
O	1,946	4,928	17,22	22,488	1,306	11,299	21,915	3 квартал
TR	1,226	5,869	6,16	59,204	9,611	19,904	9,913	2 квартал
X	1,679	2,751	20,847	24,271	1,164	8,054	11,333	4 квартал
Y	47,524	318,159	506,352	1888,74	3,73	9,386	16,845	3 квартал
P	-	-	-	-	-	-	-	3 квартал
M	0,971	0,999	16,801	11,87	0,707	5,777	8,416	4 квартал
N	22,377	131,341	335,118	1027,65	3,067	6,677	12,781	4 квартал
CO	11,284	73,680	230,888	807,409	3,497	4,887	9,126	4 квартал

Таблица 1. Анализ основных экономических показателей РФ

Компьютерное конструирование неорганических веществ с использованием методов обучения ЭВМ

Н.Н. Киселева

(Москва)

Разработка теоретических методов поиска новых неорганических веществ с заданными свойствами является одной из важнейших проблем

химии и материаловедения. Традиционные методы на основе теоретической физики и химии пока не позволяют рассчитать сложные конденсированные системы. Один из наиболее перспективных путей решения проблемы связан с использованием нового подхода, возникшего на стыке химии и современной информатики, - с компьютерным конструированием неорганических веществ и материалов. Основная гипотеза, лежащая в основе этого метода: фундаментальные свойства многокомпонентных неорганических веществ при различных условиях (температуре, давлении, соотношении компонентов и т.д.) связаны периодическими зависимостями с фундаментальными свойствами химических элементов, входящих в их состав. Предполагается, что многочисленные, известные к настоящему времени, неорганические вещества подчиняются этим закономерностям. Компьютерное конструирование новых неорганических веществ направлено, в первую очередь, на решение задачи поиска периодических закономерностей, связывающих фундаментальные свойства известных неорганических веществ со свойствами образующих их химических элементов. Найденные закономерности используются для предсказания количественного и качественного состава еще неполученных веществ и оценки их фундаментальных свойств (например, типа кристаллической структуры (при различных условиях), наличия центра симметрии кристаллической решетки, температуры плавления, температуры перехода в сверхпроводящее состояние и т.д.). Для поиска закономерностей нами применяются методы анализа данных, используемые информатикой для поиска сложных зависимостей в больших объемах данных: методы, основанные на обучении интеллектуальных систем, и ассоциативные структуры данных – растущие пирамидальные сети, ускоряющие процесс поиска взаимосвязей [1], а также разработанные нами БД по свойствам неорганических веществ и материалов, выполняющие функцию источника достоверной информации для последующего компьютерного анализа.

Задача поиска закономерностей в информации БД по свойствам неорганических веществ формулируется следующим образом. Пусть i -ый химический элемент определен набором M свойств $(x_{i1}, x_{i2}, \dots, x_{iM})$. Тогда K -компонентное химическое соединение описывается точкой в $M \cdot K$ -мерном пространстве свойств компонентов. Из-за периодичности свойств химических элементов, точки, соответствующие комбинациям близких по химической природе элементов, должны образовывать компактные классы в этом многомерном пространстве. Пусть из БД выбран некоторый набор химических соединений (в общем случае следует говорить о физико-химических системах, образованных различными элементами), для которых известна принадлежность к разным классам (*обучающая выборка*). При этом каждая физико-химическая система задается набором значений свойств образующих ее элементов. Необходимо построить в $M \cdot K$ -мерном

пространстве гиперповерхность (геометрический аналог искомой закономерности), разделяющую физико-химические системы одного класса от систем других классов. Предполагается, что, вследствие периодичности свойств, полученные разделяющие поверхности можно использовать для определения статуса еще неисследованных физико-химических систем. Этот процесс *прогнозирования* требует знания только свойств химических элементов или более простых соединений, образующих неизученную физико-химическую систему. Таким образом, задача поиска веществ, подобных уже исследованным, сведена к классической задаче обучения ЭВМ классификации объектов.

Использование методов обучения ЭВМ для анализа информации БД по свойствам неорганических веществ и материалов позволило найти периодические закономерности образования соединений разных типов и осуществить прогноз тысяч новых соединений разного состава и оценку некоторых их свойств [2-7]. Многие из предсказанных соединений являются перспективными веществами для создания новых материалов, обладающих магнитными, сверхпроводящими, полупроводниковыми, электрооптическими, акустооптическими, нелинейнооптическими, сегнетоэлектрическими и т.д. свойствами. Экспериментальная проверка наших прогнозов, проведенная в нашем Институте и в других исследовательских организациях, показывает, что средняя достоверность прогнозирования превышает 80 %. Ни один известный теоретический метод не дает такой высокой точности априорного прогноза новых соединений.

В таблице 1 дан пример прогноза типа кристаллической структуры для соединений состава $A_2B_2(XO_4)_3$. Прогнозирование соединений со структурой лангбейнита, перспективных для поиска новых лазерных материалов, было проведено нами с коллегами из ИК НАНУ по заказу USAF Wright Laboratory [7]. Используются следующие обозначения: **L** – прогноз образования соединения с кристаллической структурой лангбейнита; **K** – прогноз образования соединения со структурой типа $K_2Zn_2(MoO_4)_3$; * – прогноз отсутствия соединения состава $A_2B_2(XO_4)_3$ в системе А-В-Х-О при нормальных условиях получения; (**L**), (**K**) – соединение с соответствующим типом кристаллической структуры при нормальных условиях было известно и информация о нем была использована для обучения ЭВМ; \leftrightarrow – соединение с типом кристаллической структуры, отличным от лангбейнита или $K_2Zn_2(MoO_4)_3$, получено при нормальных условиях и информация о нем была использована для обучения ЭВМ; (*) – соединение состава $A_2B_2(XO_4)_3$ не получено в системе А-В-Х-О и информация об этом была использована для обучения ЭВМ; пустые ячейки и ? – неопределенный результат; серые ячейки – прогнозы были проверены и полностью подтверждены экспериментом.

Таблица 1. Прогноз типа кристаллической структуры соединений состава $A_2B_2(XO_4)_3$.

X	S					Cr					Mo			
	Na	K	Rb	Cs	Tl	Na	K	Rb	Cs	Tl	Na	K	Rb	Cs
B														
Mg	L	(L)	(L)	(*)	L	L	L		L	L	K	(K)	(L)	(L)
Ca	(*)	(L)	L	(L)	(*)			L	L	L	(*)	?	?	?
Mn	(*)	(L)	(L)	L	(L)	L		(L)	L	L	K	↔	(L)	(L)
Fe	*	L	L		(L)	L	K	L	L	L	K	K	?	?
Co	(*)	(L)	L		(L)	L	K	L	L	L		(K)	(L)	(L)
Ni	(*)	(L)	L	L	L	L		L	L	L	K	(K)	(L)	(L)
Cu	(*)		L	*	L	L	K	L	L	L	K	(K)	?	?
Zn	*	(L)	L	*	L	L	K	L	L	L	↔	(K)	(K)	-
Sr	(*)	?	?		(*)	*	*	?	?	?	(*)	?	?	?
Cd	(*)	(L)	(L)		(L)							K	↔	(L)
Ba	(*)		(*)	(*)	(*)	*	*				(*)		*	*
Pb					*	(*)	*	*	*	*	(*)	*	(*)	*

Использование методов обучения ЭВМ позволило разработать реальные средства для решения проблемы конструирования новых неорганических соединений с заданными свойствами. Высокая достоверность прогноза при решении химических задач свидетельствует об эффективности использования предлагаемого подхода.

Литература

1. Гладун В.П. Партнерство с компьютером. Киев: Port-Royal. 2000. 119 с.
2. Kiselyova N.N. Information-predicting system for the design of new materials // J.Alloys and Compounds. 1993. V.197. P. 159-165.
3. Киселева Н.Н. Применение методов искусственного интеллекта для конструирования неорганических соединений // Перспективные материалы. 1997. №4. С.5-21.
4. Kiselyova N.N., Gladun V.P., Vashchenko N.D. Computational materials design using artificial intelligence methods // J.Alloys and Compounds. 1998. V.279. P. 8-13.
5. Kiselyova N.N. Computer design of materials with artificial intelligence methods // Intermetallic Compounds. Vol.3. Principles and Practice. Ed.by J.H.Westbrook & R.L.Fleischer. John Wiley&Sons, Ltd. 2002. P. 811-839.
6. Kiselyova N.N. Databases and semantic networks for the inorganic materials computer design // Eng.Appl.Artificial Intelligence. 2000. V.13. P. 533-542.
7. Kiselyova N.N. et al. Property Prediction for Multi-Element Compounds (final report) // EOARD SPC-96-4096. 1997. 156 p.

Метод ТЕМП – распознавания музыкальных произведений

М.А. Коганов, А.В. Коганов, П.П. Кольцов

(Москва)

В данной работе описывается новый способ идентификации музыкального произведения по заранее отобранной фонотеке эталонных записей на основе специального представления фонограммы.

Введение

Решается задача идентификации цифровой фонограммы с одной из эталонных фонограмм заданной фонотеки или принятия решения, что данная цифровая фонограмма не может быть идентифицирована ни с одной фонограммой этой фонотеки. При этом, одно и то же произведение, исполненное в разных темпах, рассматривается как два различных. Распознавание должно производиться по эталону, представляющему небольшой отрезок полного произведения. Время распознавания не должно превышать реальное время исполнения произведения. Мелодический диапазон частот и относительный уровень шумов устанавливаются специально для данной фонотеки. Это – параметры адаптации.

Такой тип идентификации музыкального произведения значительно слабее человеческого узнавания мелодии. Однако он допускает значительно больше аранжировок для мелодии, нежели поэлементное сравнение числовых файлов.

Обзор метода распознавания

Решение поставленной задачи основано на том, что современная музыка базируется на темперированном строе. При таком строе частоты образуют геометрическую прогрессию. Это позволяет использовать дискретный спектр частот при анализе фонограммы (по аналогии с методом разложения компьютерного изображения на примитивы [3]). Вне мелодического диапазона, как правило, лежат частоты аккомпанемента. Они также выражают особенности трактовки основной темы, но не саму мелодию. В большинстве музыкальных жанров мощность этих частот выше мощности основной мелодии. Каким образом человек выделяет саму мелодию, пока еще не достаточно изучено.

Предлагаемый метод распознавания музыкальных произведений основан на изложенных фактах. Алгоритм работает с фонограммами в WAVE-формате. Полное время исполнения фонограммы разбивается на малые отрезки — *дискреты*. На каждом дискрете методом Фурье проводится вычисление амплитуд всех частот из семи темперированных октав — 84 тона (от контр-октавы до четвертой включительно). Частоты имеют номера (от 0 до 83) в порядке повышения тона (соответствует номеру клавиши фортепьяно с полным числом октав слева направо, если нумерация начинается с нуля). Эти номера сортируются в порядке убывания амплитуд, а при равных амплитудах — в порядке убывания частот. Для каждого

дискрета запоминается такой массив (размерности 84) – *кодон дискрета*. После этого кодоны дискретов объединяются в двухмерный массив по всем дискретам – *кодон фонограммы*.

Библиотека эталонов составляется из кодонов *эталонных* фонограмм – *эталонов*. Эталонные фонограммы отбираются до формирования библиотеки на слух человеком или автоматически из тех музыкальных произведений, которые должны быть представлены в библиотеке эталонов, и составляют *фонотеку*.

Для тестируемой фонограммы строится ее кодон. После этого для каждого эталона подбирается наиболее похожий участок кодона тестируемой фонограммы. Степень сходства определяется вычислением значения штрафной функции – *штрафа*, которая учитывает среднее взвешенное рассогласование номеров частот в кодонах дискретов эталона и фонограммы. Вес каждой частоты зависит от:

- ее собственного номера;
- номера места в кодоне дискрета эталона;
- номера места среди частот мелодического диапазона в порядке их расположения в кодоне дискрета эталона.

Для кодона тестируемой фонограммы отбираются два эталона, дающие наибольшее сходство (наименьшие значения штрафов: *минимум* и *вицемиимум*). Если разрыв между этими значениями выше *порога различия*, а значение наименьшего штрафа — ниже *порога идентификации*, то фонограмма отождествляется с самым похожим эталоном. Если превышен порог идентификации, то фонограмма признается не входящей в данную фонотеку. Если разность между значениями вицемиинимума и минимума ниже порога различия, то фонограмма признается нечетко определенной. Поскольку в основу положено разложение звукоряда по темперированному строю частот, этот метод идентификации мелодии будем называть *ТЕМП – распознаванием*.

Надо учесть, что при работе с одним музыкальным произведением временные границы дискретов его эталонной фонограммы могут не совпадать с границами дискретов его тестируемой части фонограммы. При этом амплитуды одинаковых частот на двух соответствующих друг другу дискретах эталонной и тестируемой фонограмм могут быть разными. Следовательно, результаты сортировок частот по амплитудам на этих дискретах могут не совпадать. Таким образом, значение штрафной функции при сравнении кодонов этих дискретов может быть больше нуля. А значит, в общем случае кодон тестируемой фонограммы не дает нулевого штрафа на точно соответствующем ему эталоне.

Вычисление порогов производится индивидуально для каждой библиотеки эталонов. Для каждого произведения из фонотеки, по которой построена данная библиотека эталонов, формируется тестируемая

фонограмма, длина которой больше длины эталонной фонограммы на длину одного дискрета, а начало смещено относительно эталонной фонограммы на половину дискрета в сторону начала произведения. После этого происходит распознавание данной фонограммы по библиотеке. Величины порогов определяются исходя из полученных по всем произведениям фонотеки результатов такого распознавания.

Полученные результаты

Предложенные алгоритмы показали свою эффективность в распознавании музыкальных произведений по библиотеке эталонов.

Качество распознавания по конкретной библиотеке эталонов сильно зависит от применяемого набора параметров. Это означает, что оптимизация параметров под заданную библиотеку может значительно повысить достоверность распознавания.

Для рассмотренных музыкальных произведений наиболее эффективным оказалось распознавание по частотам наибольшей мощности. Однако этот факт нельзя считать универсальным принципом.

Выделение при распознавании мелодического диапазона не улучшило качество распознавания. Это означает, что, даже в мелодическом диапазоне, частоты, соответствующие мелодии, не являются наиболее мощными и маскируются частотами аккомпанемента и шума. Вопрос о том, как выделить мелодию из сложного произведения остается нерешенным.

Расширение библиотеки, т.е. введение в нее новых эталонов обычно требует пересчета значений всех параметров, поскольку прежние значения оказываются не эффективными.

Предлагаемый метод распознавания обеспечивает очень компактную, по сравнению с размером музыкальных файлов, форму хранения эталонов музыкальных произведений. По этой же причине достигается высокая скорость сравнения тестируемой фонограммы с библиотекой.

Предлагаемый метод легко адаптируется для многопроцессорных параллельных вычислительных систем, и позволяет очень эффективно использовать их ресурсы.

Литература

1. Г. А. Фридкин. Практическое руководство по музыкальной грамоте. М., "Музыка", 1994.
2. И.В. Способин. Элементарная теория музыки. М., "Государственное музыкальное издательство", 1951.
3. А. В. Коганов. Метод контурных моделей в распознавании визуальных образов. "Вопросы кибернетики" (Распознавание видеографической информации) под ред. В. Б. Бетелина. РАН, М., 1999, С. 75-91

Анализ динамических кривых применительно к задаче верификации рукописной подписи

Д.В. Колядин

(Москва)

Введение

Последнее время активно разрабатываются методы подтверждения личности человека, учитывающие его индивидуальные биологические особенности. В настоящий момент наибольшее распространение получили виды аутентификации пользователя, основанные на сканировании радужной оболочки глаза, глазного дна и отпечатков пальцев. Наряду с этими технологиями достаточное, но существенно меньшее распространение получила верификация личности человека по рукописной подписи. К достоинствам данной технологии следует отнести отсутствие необходимости в дорогостоящих сканерах, а также тот факт, что в обществе имеется устоявшаяся традиция заверки документов рукописной подписью.

Постановка задачи

В работе подвергаются анализу динамические кривые, т.е. кривые для которых известна история их написания. Традиционный подход к задаче верификации рукописной подписи соответствует стандартной процедуре авторизации в компьютерных системах, когда на вход системы подается идентификатор пользователя (login) и рукописная подпись (password). Развиваемый в работе подход базируется на использовании подписи как самодостаточного объекта: подпись является login и password одновременно. Схематичное представление системы представлено на рис. 1.

Методы решения задачи верификации

В работе, главным образом, исследовался вопрос эффективного поиска соответствующего эталона в базе данных. Реальные подписи, как правило, сильно отличаются по характеру выполнения штрихов, количеству сегментов, и другим «грубым» характеристикам. Данная особенность позволяет существенно ускорить поиск нужного образца. Поэтому в модуле предобработки введенная подпись анализировалась по следующим критериям:

- соотношению ширины к высоте ограничивающего прямоугольника
- наличию протяженных горизонтальных росчерков
- количеству сегментов
- гистограммам распределения x и y компонент точек

Для построения более точных алгоритмов проводился анализ подписи на предмет выделения характерных точек:

- «вертикальных» экстремумов ($\frac{dy}{ds} = 0$)
- «горизонтальных» экстремумов ($\frac{dx}{ds} = 0$)
- экстремумов по кривизне
- точек перегиба

Обработка подписи проводилась в несколько этапов: сначала делалась эквидистантная обработка кривой (resampling), после чего подпись представлялась с помощью нормальных кубических сплайнов.



Рис. 1. Схема процесса верификации подписи, положенного в основу описываемой технологии.

На следующем этапе находились экстремальные точки всех выше перечисленных типов, которые затем подвергались фильтрации. После чего проводилась сегментация подписи. Особое внимание при этом уделялось возможной вариативности подписи. В данной работе в качестве подписей использовались имена, т.к. эти слова образуют класс близких по своему начертанию сигнатур, что создает определенные проблемы в составлении алгоритмов поиска и сопоставления, и накладывает дополнительные требования на систему. Выделенные сегменты представлялись в виде Безье-сплайнов.

Сравнение различных начертаний производилось методом динамического программирования, реализующим модифицированный алгоритм DTW (dynamic time warping), также известный как string matching.

Заключение

Основной акцент в работе был сделан на разработку алгоритма,

позволяющего проводить поиск эталона в базе данных на основе информации о сегментной структуре подписи. Кроме того, данный подход позволяет производить верификацию личности пользователя не только по рукописной подписи, но и по рукописному тексту, что является более сложной, но перспективной задачей.

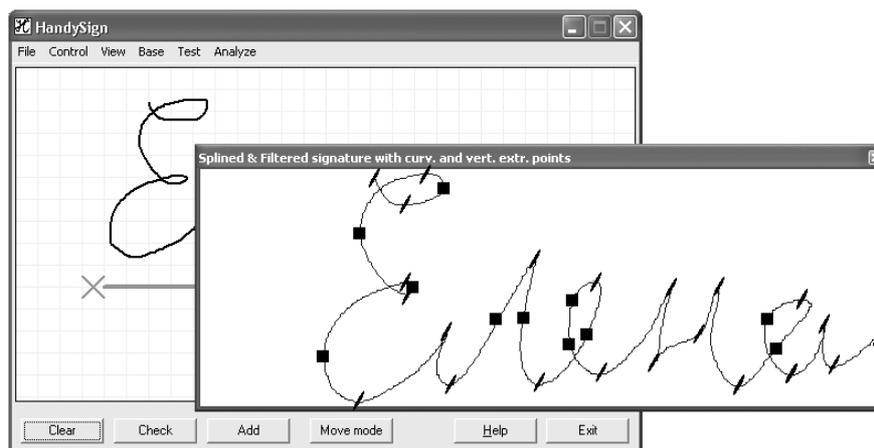


Рис. 2. Внешний вид программы с примером проведенной сегментации.
(С целью улучшения восприятия изображения граничные точки сегментов помечены косыми черточками, а остальные точки квадратами.)

К недостатком описываемого подхода следует отнести чувствительность алгоритма к смене типов экстремальных точек, что иногда приводит к неоправданному превышению штрафа за соответствие, что в свою очередь может привести к не нахождению эталона. В дальнейшем предполагается улучшение описанного подхода и организация обратной связи для подстройки под конкретного пользователя.

Литература

1. Jain A.K., Griess F.D., Connell S.D. On-line Signature Verification // Pattern Recognition, vol. 35, no. 12, pp. 2963-2972, Dec 2002.
2. Edson J.R. Justino, Flávio Bortolozzi, Robert Sabourin. The Interpersonal and Intrapersonal Variability Influences on Off-Line Signature Verification Using HMM // SIBGRAPI 2002, pp. 197-202
3. Колядин Д.В., Савин А.А. О проблеме верификации подписи в системах контроля доступа // Обработка информации и моделирование. Сборник научных трудов, стр.81-89, М. 2002
4. Hans-Leo Teulings, Lambert R.B. Schomaker, Jan Gerritsen, Hans Drexler, Marc Albers. An Online Handwriting-Recognition System Based On Unreliable Modules // 4th International Graphonomics Society Conference, Trondheim, 24-26 July 1989

Процедура совмещения изображений для формирования симметричных мер сходства

А.В. Копылов, А.С. Ермаков, А.И. Татарчук
(Тула)

Беспризнаковый подход к распознаванию образов предполагает поиск некоторой численной характеристики попарного сходства объектов распознавания, представляющую собой двухместную функцию, которая определена на множестве всех мыслимых объектов. Применительно к задаче распознавания изображений естественно предположить, что такая характеристика сходства должна быть симметрична относительно сравниваемых изображений, и, кроме того, должна учитывать наличие искажений, характерных для каждого конкретного вида прикладных задач, например, различий в ракурсе съемки и мимике лица при распознавании фотопортретов людей, и т.п.

С целью компенсации подобных, в большинстве случаев нелинейных искажений, в предыдущих работах [1, 2] был разработан способ измерения попарного сходства изображений на основе эластичного преобразования $\mathbf{V} = (\mathbf{v}_i = (v_{1,i}, v_{2,i}), \mathbf{i} \in \mathbf{I})$ дискретного растра $\mathbf{I} = \{\mathbf{i} = (i_1, i_2), i_1 = 1, \dots, n_1, i_2 = 1, \dots, n_2\}$ одного из изображений \mathbf{x}'' , называемого ссылочным, относительно базового изображения \mathbf{x}' , при котором идентичные точки на сравниваемых изображениях занимают одинаковое положение. Если изображение представлено как вектор яркости его элементов, то эластичная мера сходства может быть найдена, например, как:

$$K(\mathbf{x}', \mathbf{x}'') = \sum_{\mathbf{i} \in \mathbf{I}} x'_i x''_{\mathbf{i} + \mathbf{v}_i},$$

а само эластичное преобразование \mathbf{V} - исходя из минимума критерия:

$$\hat{\mathbf{V}} = \arg \min_{\mathbf{V}=(\mathbf{v}_i, \mathbf{i} \in \mathbf{I})} \left(\left(\sum_{\mathbf{i} \in \mathbf{I}} (x'_i - x''_{\mathbf{i} + \mathbf{v}_i})^2 \right)^{1/2} + \beta \sum_{(\mathbf{i}, \mathbf{j}) \in G} \| \mathbf{v}_i - \mathbf{v}_j \|^2 \right),$$

который выражает требование с одной стороны как можно более полного совпадения изображений при деформации, а с другой стороны учитывает априорные соображения о гладкости или «эластичности» преобразования растра. Здесь G граф непосредственного соседства элементов дискретного растра, имеющий форму прямоугольной решетки

Однако сам способ формирования эластичного преобразования, при котором координатные смещения \mathbf{v}_i элементов ссылочного изображения определены относительно растра базового, приводит к тому, что если в качестве базового будет выбрано другое изображение из сравниваемой пары, то построенная мера несходства будет основана на сравнении между собой

других компонентом векторов изображений, и в общем случае симметрия меры сходства не будет обеспечена $K(\mathbf{x}', \mathbf{x}'') \neq K(\mathbf{x}'', \mathbf{x}')$.

Для построения симметричной процедуры предположим, что растры обоих изображений подверглись эластичному преобразованию, относительно некоторого гипотетического «среднего» изображения $\mathbf{x} = \{x_i, i \in I\} \in \mathbb{R}^n$. При этом элементу i данного изображения будет поставлен в соответствие элемент $i + v_i/2$ левого изображения и элемент $i - v_i/2$ правого.

Таким образом, принятие в некоторой точке «среднего» изображения гипотезы о значении вектора смещений $\mathbf{v}_i \in \mathbf{V}$, немедленно определяет пару соответствующих элементов на сравниваемых изображениях. В этом случае мера сходства изображений принимает следующий вид:

$$K(\mathbf{x}', \mathbf{x}'') = \sum_{i \in I} x'_{i+v_i/2} x''_{i-v_i/2}$$

и является симметричной, согласно принятому способу определения эластичной трансформации.

Само эластичное преобразование $\mathbf{V} = (\mathbf{v}_i = (v_{1,i}, v_{2,i}), i \in I)$ может быть, как и для несимметричной меры сходства, найдено путем минимизации целевой функции

$$\hat{\mathbf{V}} = \arg \min_{\mathbf{V}=(\mathbf{v}_i, i \in I)} \left(\sum_{i \in I} (x'_{i+v_i/2} - x''_{i-v_i/2})^2 \right)^{1/2} + \beta \sum_{(i,j) \in G} \| \mathbf{v}_i - \mathbf{v}_j \|^2$$

посредством процедуры динамического программирования с использованием древовидной аппроксимации решетчатого отношения соседства между элементами раstra изображения [3, 4]. Однако в процедуре, использующей непосредственное запоминание функции Беллмана на очередном шаге в виде двумерного целочисленного массива, при сравнении элементов изображений должна быть применена интерполяция значений яркости, так как их координаты уже не будут целочисленными.

Результат применения процедуры построения симметричной эластичной деформации показан на рисунке 1. Среднее изображение (рис. 1 (б)) получено усреднением яркости пар соответствующих друг другу точек левого (рис. 1 (а)) и правого (рис. 1 (в)) снимков, координаты которых определяются посредством симметричного эластичного преобразования его прямоугольного раstra.

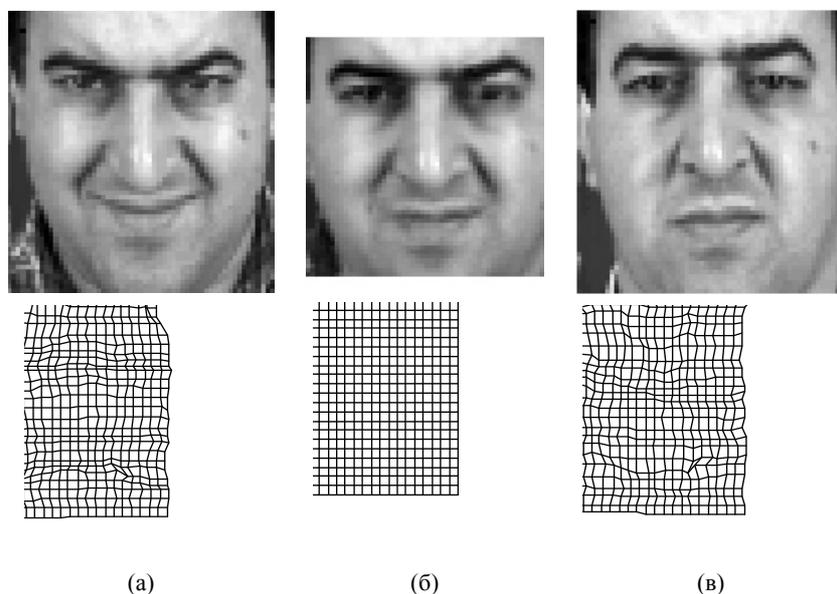


Рис. 1. Симметричное эластичное преобразование. (а) и (в) – сравниваемые изображения и искажения сетки их раstra относительно среднего изображения; (б) – изображение полученное усреднением значений яркости соответствующих друг другу элементов двух сравниваемых изображений (а) и (в).

Литература

1. V. Mottl, A. Kopylov, A. Kostin, A. Yermakov, J. Kittler. Elastic transformation of the image pixel grid for similarity based face identification. Proceedings of the 16th International Conference on Pattern Recognition, August 11-15, 2002, Quebec City, Canada.
2. V. Mottl, A. Kopylov, A. Kostin, A. Yermakov, J. Kittler. Elastic Kernel Functions for Image Recognition. Pattern Recognition and Image Analysis, Vol. 13, No. 1, 2003, pp. 98–100.
3. Mottl V., Kopylov A., Blinov A., Kostin A. Optimization techniques on pixel neighborhood graphs for image processing. // Graph-Based Representations in Pattern Recognition (J.-M. Jolion and W.G. Kropatsch, ed.). Computing, Supplement 12. Springer-Verlag/Wien, 1998, pp. 135-145.
4. Mottl V., Kopylov A., Blinov A., Kostin A. Computer-aided signal and image processing: A universal variational approach. // Journal of Journals: Review of Global Scientific Achievements, 1998, Vol. 2, No. 1, pp. 23-30.

Принципы реализации комплексного распознавания искусственных космических объектов по многоспектральной видовой информации

А.В. Корякин
(Санкт-Петербург)

Растущие масштабы освоения околоземного космического пространства предполагают совершенствования национальных систем наблюдения за искусственными космическими объектами (ИКО) с использованием информационных оптико-электронных систем (ОЭС) различного варианта базирования. Система комплексного распознавания ИКО по многоспектральным изображениям является распределенной информационно-измерительной системой, содержащей в своем составе разнородные ОЭС различного варианта базирования, предназначенные для получения ВИ в оптическом диапазоне о космических объектах в интересах решения задач распознавания, а также формирования эталонов [1, 2, 3, 4].

Рассмотрим основные принципы реализации процесса комплексного распознавания ИКО по многоспектральной ВИ с использованием комбинированного подхода к описанию изображения на основе моментных инвариантов и атрибутных графов. Эти принципы можно объединить в три смысловых блока: информационного, аппаратурного и программно-алгоритмического.

В состав *информационного блока принципов* входят следующие основные положения.

Во-первых, планирование наблюдения ИКО в оптическом диапазоне спектра предполагает имитационное моделирование «реалистичных» изображений наблюдаемой сцены и предварительную оценку целевой пригодности ВИ [2]. Имитационное моделирование проводится при условии выполнения всех ограничений, накладываемых на процесс получения качественных изображений ИКО со стороны баллистических и геометрических, радиологических факторов космического пространства и орбитального движения. Оценка целевой пригодности формируемых изображений должна проводиться на основании критериев, в основу которых положены принципиальные теоретические положения структурно-параметрического описания многоспектральных изображений, наиболее полно учитывающие пространственную структуру наблюдаемой поверхности ИКО [5, 6].

Во-вторых, для формирования эталонной информации используются многоспектральные оптические изображения, полученные методом математического моделирования с использованием специализированных программных комплексов [4].

В третьих, для хранения и накопления разнородных массивов специализированной информации, необходимой для вычислительных

операций при комплексном распознавании ИКО, предполагается архитектура построения интегрированной глобальной базы данных, которая позволяет накапливать:

- опτικο-геометрические модели ИКО [4];
- таблицы, описывающие эталонное представление структуры поверхности наблюдаемых ИКО;
- файлы цифровых изображений исходной многоспектральной ВИ;
- морфометрическое описание преобразованных изображений ИКО для различных условий наблюдения и освещения [5, 6].

В состав **аппаратурного блока принципов** входят следующие основные рекомендации:

Во-первых, оптическая и приемная подсистемы информационной ОЭС должны строиться на принципе совмещения во времени и в пространстве многоспектральной ВИ высокого разрешения в рамках единой оптической схемы. Целесообразно и технически оправдано использование однотипных матричных фотоприемных устройств кадрового типа, позволяющих получать изображения в выбранных спектральных каналах.

Во-вторых, конструкционные материалы и покрытия ОЭС должны обеспечивать техническую реализацию нескольких спектральных каналов формирования детальных изображений, включающие ближний ультрафиолетовый и несколько каналов в видимом и ближнем инфракрасном участках оптического спектра излучения.

В-третьих, оптическая и приемная подсистемы должны быть оснащены аппаратурой и программными средствами удержания ИКО в пределах границ кадра, сопровождения, компенсации эффекта пространственного размазывания изображения.

В-четвертых, для получения оптических изображений высокого качества эффективно использование принципов адаптивной оптики для компенсации искажений, вызванных атмосферной турбулентностью и не стабильностью функционирования бортовой системы стабилизации в случае орбитального базирования ОЭС [7].

В состав **программно-алгоритмического блока принципов** реализации комплексного распознавания ИКО по многоспектральной ВИ входят следующие основные принципы:

Комплексирования. Программная реализация принципа комплексирования основана на использовании единой области накопления и хранения данных и знаний по анализируемым изображениям.

Многоуровневой структурно-параметрической декомпозиции. Принцип основан на операциях оптимальной алгоритмической реализации оператора топологического замыкания и оценивания характеристик рельефа наблюдаемой поверхности ИКО по многоспектральным изображениям в пределах локальных связных областей [5, 6, 8].

Информационного наследования. Принцип основан на использовании динамической базы данных анализируемого изображения, которая формируется по результатам многоуровневой сегментации [9]. Принцип реализован при совместной обработке ВИ на всех этапах формирования структурно-параметрического описания многоспектральных изображений.

Наиболее перспективным направлением программной реализации на настоящий момент следует признать объектно-ориентированное программирование (ООП). Разработанная пространственно согласованная транспарантная модель морфометрического описания многоспектральных изображений ИКО позволяет реализовать все преимущества ООП [6]. Разработанный вариант программной реализации автоматизированной обработки многоспектральной ВИ для идентификации ИКО позволяет сохранять знания и параметры сценария обработки многоспектральных изображений, чтобы затем использовать при автоматической обработке. Система программ обработки многоспектральных изображений ИКО позволяет проводить распознавание в трех режимах: исследовательском, обучения, штатного функционирования [10].

Литература

1. Корякин А.В., Лутов И.О. Двухуровневая стратегия комплексной обработки разнородной видовой информации о космических объектах// Труды VIII Всероссийской конференции «Математические методы распознавания образов», ВЦ РАН, 1997 г., с. 174-176.
2. Корякин А.В. Направления разработки систем распознавания космических объектов по разнородной видовой информации// Труды IX Всероссийской конференции «Математические методы распознавания образов», Вычислительный центр РАН, 1999 г., с. 202-204.
3. Корякин А.В. Комплексное распознавание трехмерных объектов по разнородной видовой информации с использованием теории коллективных решений// Труды X Всероссийской конференции "Математические методы распознавания образов". –М.: ВЦ РАН, 2001, с. - 225-228.
4. Корякин А.В., Лебедев Э.К. Формирования эталонов в задачах распознавания КО по видовой информации// Труды VIII Всероссийской конференции «Математические методы распознавания образов», ВЦ РАН, 1997 г., с. 172-174.
5. Koryakin, A.V., Basic Principles of Applied Theory of Recognition of Artificial Cooperative Objects Using Visual Information, Pattern Recognition and Image Analysis, Vol.11, No.1, 2001, pp.198-201.
6. Koryakin, A.V., Structural-Topological Model of Spacecraft Images Formed Using a Photodetector Array under Different Monitoring Conditions of Observation, Pattern Recognition and Image Analysis, Vol.11, No.1, 2001, pp.202-204.

7. Клейменов Е.В., Корякин А.В. Оценка качества изображений в адаптивных оптических телескопах // Труды VI Международной конференции «Распознавание образов и анализ изображений: новые информационные технологии», Великий Новгород, НГУ, 2002 г.
8. Корякин А.В. Оценка характеристик глубины сцены по картине полутонов изображений космических объектов// Оптический журнал, том №67, №7, 2000г., с.28-33.
9. Корякин А.В. Синтезированное описание трехмерных сцен на основе совместной обработки разносектральных изображений// Труды X Всероссийской конференции "Математические методы распознавания образов". –М.: Вычислительный центр РАН, 2001, с. - 228-231.
10. D'yachenko, D.A., Koryakin, A.V., Object-Oriented Approaches to Image Processing Automation, Pattern Recognition and Image Analysis, Vol.11, No.2, 2001, pp.425-427.

Совместный учет яркостной и координатной информации при опознавании астроориентиров

А.В. Кривецкий, С.Е. Чесноков, А.С. Авраменко

(г. Йошкар-Ола)

Качество распознавания изображений групповых точечных ориентиров (ГрТО), определяет уровень сбоев, точность и скорость установления в переходных режимах работы современных аналитических систем ориентации. Чем выше достоверность распознавания, тем выше (при прочих равных) значения данных показателей.

Несмотря на важность, вопрос о потенциально достижимой достоверности распознавания астроориентиров еще не решен. Предлагаемые в публикациях алгоритмы распознавания направлены, в основном, на повышение быстродействия принятия решений, носят эвристический характер и в качестве дискриминационных используют только координатные признаки.

В настоящей работе на основе спектральных и статистических свойств зашумленных изображений астроориентиров синтезируются оптимальный и квазиоптимальный алгоритмы распознавания ориентиров, позволяющие учесть, помимо координатной, информацию о яркости отдельных точечных ориентиров.

Основными мешающими факторами при обработке изображений ГрТО являются яркостный, координатный и импульсный шумы.

Благодаря точечному характеру изображений отдельных ориентиров наблюдаемый машинный кадр может быть представлен с помощью аддитивной интегральной модели шумов.

Следующее из данной модели представление шумовой составляющей

кадра при принятых для телевизионных астрономических изображений распределениях отдельных шумовых составляющих обладает неравномерным энергетическим спектром.

Оптимальное устройство распознавания изображений групповых ориентиров на фоне таких шумов может быть построено по схеме «отбеливающее звено + оптимальный (в байесовском смысле) приемник на фоне белого шума».

Суть модификации данного алгоритма на основе минимальной достаточной статистики состоит в следующем. Наблюдаемое изображение с целью «обеления шумов» подвергается низкочастотной пространственной фильтрации. Затем вычисляются взаимные корреляционные функции (ВКФ) этого изображения с эталонными изображениями, прошедшими через такой же фильтр. Решение выносится в пользу эталона с максимальным значением ВКФ.

Недостатком данного алгоритма является высокая трудоемкость при априорной неопределенности относительно смещения и угловой ориентации изображений.

Для обеспечения реального масштаба времени распознавания ориентиров в условиях априорной неопределенности выполняется снижение размерности описания изображений ГрТО, прошедших через отбеливающее звено, путем использования лишь выборки отсчетов. Для обеспечения инвариантности сокращенного описания к повороту и смещению изображений в качестве выборочных использованы отсчеты, расположенные на концентрических окружностях с центрами в точечных объектах, применено их комплекснозначное кодирование [1,2]. Такой способ кодирования сосредотачивает информацию о повороте изображения в равном приращении аргументов комплексных отсчетов. Синтезированный оптимальный байесовский алгоритм распознавания таких кодов сводится к нахождению максимального значения из значений модулей циклических ВКФ наблюдаемого кода с эталонными кодами и схож с алгоритмом распознавания радиосигналов с неизвестной начальной фазой. Сочетание рассмотренного метода сокращения размерности описания и оптимального алгоритма распознавания кодов составляют квазиоптимальный алгоритм распознавания групповых точечных ориентиров.

Оба алгоритма при вынесении решения учитывают как координатную информацию о взаимном расположении точечных объектов, так и яркостную информацию. В обоих случаях наибольший вклад во вторичное описание изображений вносят наиболее яркие объекты, пропуск которых существенно менее вероятен.

Сравнительный анализ эффективности полученных алгоритмов идентификации ГрТО с известными показал, что оптимальный алгоритм действительно обладает наивысшей достоверностью. Квазиоптимальный

алгоритм, незначительно проигрывая в отношении сигнал/шум оптимальному и трудоемким квазикорреляционному, обладает приблизительно на 3 порядка большим быстродействием и выигрывает по достоверности выносимых решений в классе известных алгоритмов распознавания ГрТО реального масштаба времени.

Литература

1. Введение в контурный анализ и его приложения к обработке изображений и сигналов/ Я.А.Фурман, А.В.Кревецкий, А.К.Передреев, А.А.Роженцов, Р.Г.Хафизов, И.Л.Егошина, А.Н.Леухин; Под ред. Я.А.Фурмана. – М.: ФИЗМАТЛИТ, 2002. – 592 с.
2. Кревецкий А.В., Чесноков С.Е. Кодирование и распознавание изображений множеств точечных отметок на основе моделей физических полей/ Автометрия, 2002, №3. – С.80-89.

Выравнивание аминокислотных последовательностей для независимых позиционных наблюдений

Е.Н. Кузнецов, Ш.Р. Сюняев, В.Г. Туманян

(Москва)

Несмотря на многолетние усилия, задача прямого предсказания пространственной структуры белка по его аминокислотной последовательности все еще далека от своего решения. И хотя, благодаря успехам экспериментальных методов, в особенности рентгеноструктурного анализа и ЯМР, в результате многочисленных “геномных” проектов число белков с известной трехмерной структурой постоянно растет, разрыв между числом известных аминокислотных последовательностей и числом известных структур белков катастрофически увеличивается. В то же время, в последние годы предложен ряд количественных критериев для **распознавания** структуры белка по его аминокислотной последовательности (см., например, [1-4]).

Приводится обзор одного класса современных методов определения структуры белка по его аминокислотной последовательности (так называемый “*трединг*”, от “threading” - нанизывание).

Другое направление в исследовании белков с неизвестной трехмерной структурой – **профильные методы** – основано на множественном выравнивании подмножества аминокислотных последовательностей белков, составляющих некоторое (структурное) семейство [1]. Изложена основная схема и особенности реализации профильных методов. Для этих методов распознавание родственного семейства для заданной аминокислотной последовательности основано на статистическом анализе распределений аминокислотных остатков различного типа в последовательностях аминокислотных остатков (АКО) белков с известной третичной структурой

(на обучении).

В [5] рассмотрен метод множественного выравнивания последовательностей с учетом независимых наблюдений в каждой позиции (PSIC – метод от «position specific independent counts»).

В настоящей работе разработан простой и быстрый метод вычисления весов для каждой позиции каждой последовательности в рамках подхода, основанного на оценке расстояния между последовательностями для PSIC - метода. При вычислении профиля, нет необходимости явного определения этих весов. Вместо этого, они неявно оцениваются в форме “фактических” вероятностей встретить каждый из типов аминокислот в каждой позиции. Для получения этих вероятностей подсчитывается “эквивалентное число независимых наблюдений” аминокислот разных типов в каждой позиции множественного выравнивания. Формулы расчета этого числа вполне согласуются с интуитивными представлениями. В частности, пусть некая аминокислота *a* на позиции *n* в изучаемой последовательности *j* встречается в той же позиции у некоторого числа *m* других последовательностей из множественного выравнивания. Тогда “эквивалентное число независимых наблюдений” оказывается близким к единице, если эти последовательности почти совпадают друг с другом, и значительно больше единицы, если эти последовательности вполне независимы [5].

Представленные статистические методы были протестированы на белках с известной пространственной структурой и функцией, и определены оптимальные значения параметров. Было продемонстрировано преимущество предложенного метода для большинства белковых семейств. Программа профильного анализа установлена на WWW сервер, и к нему есть обращения из многих стран. В настоящее время удаленный пользователь передает на сервер множественное выравнивание белкового семейства в формате CLUSTAL и ему в ответ передается рассчитанный профиль соответствующего семейства в формате GCG. При этом используется собственная программа поиска в белковой базе данных, работающая с профилями.

Проведено исследование по проверке пределов применимости теоретических предположений, лежащих в основе методов нанизывания (трединга), и выявлению фундаментальных ограничений этих методов. Выделены значимые и незначимые предпочтения аминокислотных остатков к определенным структурным положениям. Показано, что семь аминокислотных остатков невозможно локализовать в структуре с использованием общепринятых структурных характеристик.

Продемонстрировано, что профили, полученные из множественных выравниваний методом PSIC, оказываются высоко эффективными в обнаружении далеких членов структурных семейств белков.

Расчеты по представленным методам осуществляются в Институте молекулярной биологии им. В.А.Энгельгардта (ИМБ) РАН и в Европейской лаборатории молекулярной биологии (EMBL). Часть программ доступна для бесплатного получения через Интернет на FTP-серверах ИМБ и EMBL. Кроме того, сервисный расчет профилей множественного выравнивания по методу PSIC доступен через WWW-интерфейс по адресу URL=www.imb.ac.ru/PSIC.

Литература

1. Eisenhaber F., Persson B., Argos P. Critical Reviews in Biochemistry and Molecular Biology. 1995. V. 30 (1). P. 1-94.
2. Сюняев Ш.Р., Кузнецов Е.Н., Туманян В.Г. Новые критерии в обратной задаче структурообразования белка // Биофизика. 1994. Т. 39. С. 972-978.
3. Shamil Sunyaev, Eugene Kuznetsov, Igor Rodchenkov and Vladimir Tumanyan. Mathematical forms of protein structure and sequence compatibility criteria // Protein Engineering, 1997, V.10, No 6, P.167-178.
4. Shamil R. Sunyaev, Frank Eisenhaber, Patrick Argos, Eugene N. Kuznetsov, and Vladimir G. Tumanyan. Are knowledge-based potentials derived from protein structure sets discriminative with respect to amino acid types? // Proteins: Structure, Function and Genetics. 1998, v.31, P.225-246.
5. Shamil R. Sunyaev, Frank Eisenhaber., Igor V. Rodchenkov, Birgit Eisenhaber, Vladimir G. Tumanyan, Eugene N. Kuznetsov. PSIC: Profile extraction from sequence alignments with position-specific counts of independent observations // Protein Eng. 1999, V.12, N 5, P.387-494.

Итерационное формирование описаний изображения, управляемое моделью объекта, в задаче распознавания

М.И. Кумсков, С.Ю. Сергунин, К.М. Квашинин

(Москва)

Введение

Предложено развитие информационной модели Д. Марра., построенные на этапе обучения *модели объектов* используются для итерационного представления изображений. На этапе распознавания проводится идентификации («подтверждение») тех объектов, которые предъявлялись системе на этапе обучения. Формирование «правильного» представлению изображений на этапе распознавания проводится в зависимости от «активного» объекта-кандидата на основе семейства алфавитов произвольных элементов, принадлежащих объекту.

Основным понятием у Марра является понятие представлений изображения при анализе и распознавании объектов. Под представлением понимаются «характеристики реального мира, которые в процессе

зрительного восприятия переводятся в явную форму». Марр выделил три уровня представлений – «первоначальный эскиз», «2.5-эскиз» и «3D-модель». Предлагается использовать понятие «модели объекта», которое инкапсулирует (в смысле объектно-ориентированной парадигмы) два верхнеуровневых представления - «2.5-эскиз» и «3D-модель», и позволяет динамически формировать семейство представлений первого уровня - «первоначальный эскиз». Предлагаемая схема является развитием подхода, предложенного ранее М.Кумсковым.

«Первоначальный эскиз» предназначен для представления в явном виде характеристик изображения, включая представление локальных геометрических свойств изображения с помощью произвольных элементов. Такими произвольными элементами (или элементами описания) могут быть, например, особые точки изображения, контуры определенной ориентации и т.п.

Объектная модель и Алфавит элементов описания

Назовем алфавитом элементов описания DEA (Description Element's Alphabet) четверку $DEA=(F, Ind, C, M)$, где F – функция фильтрации изображения P , формирующая новое изображение-«препарат» PR , Ind – индикаторная функция, идентифицирующая на изображении-препарате PR элементы описания De_j , C – функция классификации элементов описания

De , $M=\{m_1, m_2, \dots, m_w\}$ - область определения функции C , т.е. список классов (или символьных маркеров), которым могут принадлежать элементы описания.

$$PR=F(P); \quad Ind(PR) \rightarrow \{De_j\}; \quad C(De_j) \in M;$$

где P – исходное изображение, PR – его препарат после проведения преобразования F , $\{De_j\}$ – множество элементов описания, найденных в результате применения индикаторной функции к PR , $M_j=C(De_j)$ – маркеры, присваиваемые элементам описания, в результате их локальной классификации (типизации).

В результате применения DEA к изображению P формируется описание изображения $Descr(P, DEA)$ в виде списка пар:

$Descr(P, DEA)=\{M_j, X_j, j=1, J\}$, где J – число найденных элементов, M_j – маркер j -ого элемента описания De_j , X_j – вектор атрибутов, характеризующих j -ый элемента описания (включая координаты расположения De_j на изображении)

Назовем объектной моделью распознавания OM четверку:

$$OM=(DEA_{com}, \{DEA_k, k=1, K\}, S=\{S_k, k=0, K\}, T=\{T_k\}), \quad \text{где}$$

DEA_{com} (или DEA_0) - алфавит элементов описания, общий для всех объектных моделей; DEA_k - k -ый алфавит элементов описания, специфичный для данной ОМ; S_k - функция сравнения, вычисляющая степень близости (в интервале $[0,1]$) представления изображения в k -ом алфавите $Descr(P, DEA_k)$ к внутреннему представлению объекта, «хранящимся» в ОМ; T_k - значение порога для функции сравнения S_k - если $S_k(.) > T_k$, то считается, что на данном изображении P объект ОМ «подтверждает себя» в k -ом алфавите.

Подтверждение объектной модели при распознавании

На *этапе обучения* проводится построение списка объектных моделей (базы данных) $OMDB = \{OM_q, q=1, Q\}$, где Q - число различных объектов (классов), подлежащих распознаванию, OM_q - объектная модель, соответствующая q -му классу.

На *этапе распознавания* нового изображения Pz проводятся следующие вычисления:

1. Изображение Pz описывается в алфавите DEA_{com} (DEA_0) - формируется список $Descr(Pz, DEA_0)$.
2. Описание $Descr(Pz, DEA_0)$ поступает как запрос к базе данных $OMDB$. Каждая OM_q использует функцию S_0 для оценки близости своего (q -го) объекта полученному описанию в алфавите DEA_0 .
3. В результате запроса формируется список ОМ-кандидатов - $OM-List$, имеющих лучшие оценки близости.
4. Лучшая OM^* становится «активной» моделью. Ей «передается управление» для формирования описаний изображения Pz . Активной модели следует подтвердить свое «лидерство» при представлении изображения Pz в специализированных (для данного объекта) алфавитах $DEA_k, k=1, K$.
5. <цикл по алфавитам $OM^* : DEA_k, k=1, K$ >.
6. Изображение Pz описывается в алфавите DEA_k , принадлежащему текущей активной модели OM^* - формируется список $Descr(Pz, DEA_k)$
7. Описание $Descr(Pz, DEA_k)$ оценивается на «близость» с использованием функции S_k . Если значение близости больше

- порога T_k , то считаем, что по k-ому алфавиту произошло «подтверждение OM^* » и продолжаем цикл – переходим на п.5. Если подтверждение не произошло, то переходим на п.8. <конец цикла по алфавитам: Если все алфавиты «удачно» просмотрены, то переходим к п.9. >
8. Выбираем следующего лучшего кандидата (OM-модель) из списка OM-List. Эту модель делаем «активной» и переходим к п.4. Если список OM-List исчерпан, т.е. ни одна OM-модель не смогла себя подтвердить, то Ответ - «отказ от распознавания».
 9. Ответ – на изображении расположен объект, соответствующей текущей «активной» модели OM^* .

Заключение

Предложенный подход к динамическому и итеративному построению представлений изображения при его распознавании позволяет легко проводить дообучение системы за счет, во-первых, введения в базу данных OMDB новых «объектов» - объектных моделей, а во-вторых, за счет добавления и/или модификации алфавитов DEA, принадлежащих объектной модели. В докладе будут приведены конкретные реализации предложенного подхода и примеры алфавитов элементов описания изображений. Предложенный выше алгоритм «подтверждения объектом» своего присутствия на изображении является предварительным. Он будет исследован и в дальнейшем модифицирован в конкретных реализациях.

Литература

1. Марр Д. Зрение. Информационный подход к изучению представления и обработки зрительных образов, М., Радио и связь, 1987.
2. Kumskov M.I. Calculation Scheme of the Image Analysis Controlled by the Models of the v Objects to be Recognized //Pattern Recognition and Image Analysis, 2001, 11, N2, p. 446–449.
3. Sergunin S.Yu., Kvashnin K.M., Kumskov M.I. Using Image Representation Families for Recognition Based on Symbol Marking of Singular Points //Pattern Recognition and Image Analysis, 2003, 13, N.3, p. 531-538.

Совместное применение астролометрической методики и нейронных сетей для прогнозирования фондовых индексов

П.Г. Курочкин

(Москва)

Введение

Как известно основными методами прогнозирования динамики фондовых индексов (цен) на данный момент являются фундаментальный и технический анализы [1,2]. Эти методы, базируясь на «Теории Эффективного рынка» исходят из того, что цена актива учитывает всю информацию о нем. Таким образом констатируется, что для прогнозирования будущего движения цены актива - стоимостные факторы являются первичными.

В докладе, на основании 7-ми летнего опыта исследований автора в области взаимосвязи астролометрической (АСТРЛ) динамики и динамики фондового индекса, предпринимается попытка доказать, что динамика цен на рынке является производной величиной от динамики АСТРЛ факторов.

Что такое Астролометрия?!

Теория астролометрии базируется на следующем постулате: если динамика фондового индекса является «численной материализацией» динамики «рыночной» психологии участников торгов то, предполагая, что последняя определяется АСТРЛ процессами, прогнозирование индекса можно свести к прогнозированию АСТРЛ динамики.

Вкратце АСТРЛ можно охарактеризовать, как симбиоз астрономии, математики и астрологии. Из Астрономии взяты методы определения положения небесных тел. Из Астрологии, взяты основные астрологические факторы влияния небесных тел и понятия о качественных и количественных параметрах их взаимодействия. Математика используется для построения математической модели АСТРЛ взаимодействий.

Таким образом, астролометрией можно назвать науку о количественных и временных параметрах АСТРЛ полей, влияющих на процессы, происходящие на Земле.

Как строится астролометрическая модель фондового индекса

Поскольку идеология АСТРЛ методики базируется на первичности АСТРЛ параметров, то предполагается, что вся информация о прошлой, настоящей и будущей динамиках фондового индекса содержится в динамике АСТРЛ параметров. Из этого вытекает постулат о достаточности одних лишь только астролометрических параметров для описания динамики фондового индекса в прошлом (построения АСТРЛ модели индекса) и прогнозирования фондового индекса в будущем (применением построенной АСТРЛ модели индекса для будущих АСТРЛ параметров).

Особенности построения АСТРЛ модели рынка вытекают из особенностей вышеприведенного АСТРЛ подхода, а именно – ценовые параметры могут использоваться только в качестве выхода нейронной сети (НС), которая создает АСТРЛ модель. При этом на вход НС допускается подавать только АСТРЛ параметры. За счет этого, во-первых, появляется возможность проследить причинно-следственные связи между входными АСТРЛ параметрами и индексом, во-вторых, «глубина» такого рода прогнозирования в будущее, теоретически ограничена только периодом существования самого фондового рынка.

Нужно отметить, что для создания АСТРЛ модели индекса используется трехмерная геоцентрическая модель солнечной системы.

Для построения АСТРЛ модели рынка был использован метод группового учета аргументов (МГУА), предложенный впервые

Ивахненко А.Г.[3, 4]

Здесь необходимо отметить, что на первых этапах исследований, применялся собственный подход для построения модели рынка, при котором НС не применялась. Применение МГУА для построения АСТРЛ модели индекса позволило качественно увеличить «глубину» прогнозирования. Тем не менее возможность прогнозирования фондового индекса и без применения НС говорит о высокой информативности АСТРЛ данных.

В качестве программой реализации МГУА использовалась программа NeuroShell 2 [5].

Выходом НС служат значения индекса NASDAQ-100, начиная с 01 октября 1985 года, что объясняется доступностью данных об индексе NASDAQ-100 именно с этой даты.

Необходимость построения модели рынка на столь длительном периоде времени обусловлена достаточно длительным средним периодом обращения планет солнечной системы. Очевидно, что для построения модели любого процесса входные параметры должны как можно более полно отражать возможные значения, допустимые для конкретного входа. В этой связи входные параметры пришлось ограничить параметрами, вычисляемыми из движения только шести наиболее «быстрых» объектов солнечной системы: Солнца, Луны, Меркурия, Венеры, Марса и Юпитера, имеющих относительно небольшой период обращения. В качестве Земной «привязки» для вычисления эфемерид, был выбран город Нью-Йорк [7].

Результаты применения астролометрической модели индекса NASDAQ-100

В результате исследований в области построения АСТРЛ моделей индекса NASDAQ-100 удалось обнаружить сильные взаимосвязи между динамикой АСТРЛ параметров и динамикой индекса NASDAQ-100.

При этом по построенным АСТРЛ моделям удалось создать достаточно длительные прогнозы индекса.

Ниже, на рис.1, приводится прогноз среднеарифметического от максимального, минимального и значений на закрытие рынка, индекса NASDAQ-100 (NDX TYPICAL PRICE). На выход НС, был «подан» временной ряд NDX TYPICAL PRICE с 01 октября 1985 года по 26 марта 2002 года (всего 4161 значения). На вход НС подавались соответствующие АСТРЛ параметры, рассчитанные для каждого торгового дня (без временного смещения) – порядка 1000 входов. Вертикальная черта на рис.1

соответствует дате 26 марта 2002 года.



Рис.1 График NDX TYPICAL PRICE и его АСТРЛ прогноза.

Качество прогноза, на будущих данных индекса можно оценить с помощью статистических характеристик (СХ): нормированного среднеквадратичного отклонения (НСКО) и линейного коэффициента корреляции Пирсона, рассчитанных для временных рядов прогноза и индекса. Дата начала вычисления СХ - 27 марта 2002 года.

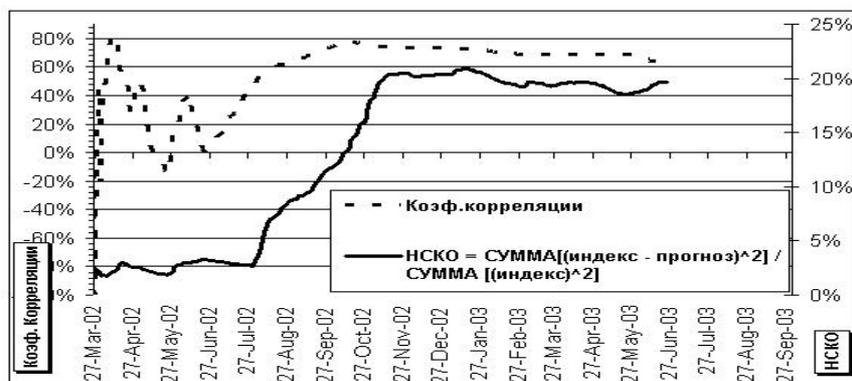


Рис.2 Статистические характеристики прогноза и NDX TYPICAL PRICE на периоде времени, после его создания прогноза.

О наличии сильной взаимосвязи между числовыми рядами NDX TYPICAL PRICE и прогноза свидетельствует тот факт, что на периоде

времени, после создания АСТРЛ модели индекса наблюдаются достаточно длительные участки стабилизации СХ. Особенно это заметно на графике НСКО, где наблюдается два таких участка. В тоже время резкий рост графика НСКО в середине рассматриваемого периода говорит о том, что АСТРЛ модель рынка на этом участке времени не учитывала каких-то значимых АСТРЛ параметров. Отчасти это связано с тем, что при создании модели не учитывались планеты, с орбитой, лежащей далее орбиты Юпитера, отчасти с реально существующими ошибками эфемерид планет, по которым вычислялись АСТРЛ параметры модели. Кроме того, существенный вклад в ошибки АСТРЛ модели вносит «шум» выходных значений индекса, которые имеет место на любом не идеально эффективном рынке. Но самый большой резерв уменьшения ошибок прогнозирования, видится в дальнейшем совершенствовании структуры АСТРЛ параметров, подаваемых на вход НС.

В связи с этим можно констатировать, что проведенные исследования не только показывают возможность математического моделирования реальных земных процессов с использованием АСТРЛ параметров, но и ставят новые вопросы, связанные с улучшением структуры данных, используемых при создании АСТРЛ моделей.

Кроме того, можно предположить, что применение АСТРЛ методики позволит прогнозировать не только фондовые рынки, но и другие глобальные процессы, происходящие на Земле.

В заключении автор выражает благодарность А.Б.Надирадзе (www.abn@hausnet.ru), за помощь, оказанную при редактировании этой статьи и компанию «Нейропроект» [6] за исчерпывающую информацию о НС и генетических алгоритмах (ГА), применительно для научно-исследовательских и инженерных задач.

Литература и иные источники информации

1. Брейли Р., Майерс С. // Принципы корпоративных финансов М.: ЗАО «Олимп-Бизнес», 1997. С. 1-1120.
2. Мерфи Джон Дж. // Технический анализ фьючерсных рынков: теория и практика М.: Диаграмма, 1998. С 1-592.
3. Ивахненко А.Г., Юрачковский Ю.П. // Моделирование сложных систем по экспериментальным данным.» М.: Радио и связь, 1987.- 120 с.
4. Международный научно-учебный Центр ЮНЕСКО информационных технологий и систем НАН Украины, страничка разработчиков МГУА – <http://www.gmdh.net/gmdh.html>
5. Торговая марка NeuroShell, является зарегистрированным товарным знаком компании Ward Systems Group Inc.(США),- <http://ww.wardsystems.com>
6. Компания «Нейропроект», - <http://www.neuroproject.ru>

7. Программа вычисления эфемерид “SwissEphemeris” –
<http://www.astrodienst.com>

**Принятие решений о значимости программных продуктов
путем их сравнения с аналогами-эталопами в базе данных
учебно-научных работ**

С.Н. Ломакин, Д.В. Солдатенков, С.А. Яковлев
(Москва)

В работе рассматривается база данных, объединяющая курсовые и дипломные проекты студентов, обучающихся по специальности «Промышленный менеджмент». Методическую основу базы данных составляют труды отечественных и зарубежных ученых: В. М. Глушкова, Ю. И. Журавлева и др. Проекты содержат данные проведенных маркетинговых исследований и рекомендации по совершенствованию организационного плана предприятий и организаций. База данных содержит элементы экспертного оценивания проектов, позволяющие, при помощи удобной для пользователя оболочки, вести учет проектов, осуществлять их сравнение между собой и с эталонными работами для выработки рекомендации по предварительному оцениванию значимости представленных работ.

Созданная для усовершенствования учебного процесса, помощи в выявлении некачественных работ и информационного обмена между ВУЗами, база данных позволяет:

- разрабатывать электронные пособия для обучения студентов;
- осуществлять защиту курсовых и дипломных проектов в электронном виде;

- исключить дублирование курсовых и дипломных проектов;

- дать объективные рекомендации по оценке работ.

Оболочка базы данных обладает следующими основными свойствами:

- удобный интерфейс;

- универсальность;

- быстрая обучаемость пользователями;

- рациональное использование информации;

- многофункциональность;

- многооконность.

База данных сопряжена с экспертной системой, выполняющей следующие функции:

- внутреннее упорядочивание объектов;

- выявление объектов-эталонов и их обновление;

- сравнение объектов базы данных с эталонами по системе количественных показателей (включая оценку частоты встречаемости ключевых слов);

оценка значимости объектов базы данных;

разработка рекомендаций по предварительному оцениванию проектов.

Таким образом, отметим, что использование экспертных систем в базе данных позволяет при помощи удобного интерфейса не только вести учет объектов, но и решать разнообразные задачи их обработки.

Построение математической модели для анализа данных МЧС

Т.И. Лучшева
(Новосибирск)

Введение

Рассматривается задача построения решающей функции распознавания в пространстве разнотипных переменных в классе логических решающих функций [1]. В данном классе строятся вероятностные логические закономерности, отражающие причинно-следственные связи изучаемых сложных объектов. Логической закономерностью называется высказывание, обладающее большим прогнозирующим свойством. Набор таких закономерностей, представленных на языке, близком к естественному языку логических суждений, является логико-вероятностной моделью изучаемого сложного объекта. При определении оптимальной функции в указанном классе появляются алгоритмические проблемы. Один из подходов к решению этой проблемы описан ниже. Логические закономерности, полученные на основе анализа данных МЧС представлены здесь как иллюстрация метода.

Рассматривается некоторая генеральная совокупность объектов Γ . Система переменных $X = (X_1, \dots, X_n)$ вводится для описания объекта $a \in \Gamma$, принадлежащего одному из k образов. Значение целевой переменной Y определяет номер образа этого объекта.

Обнаружение закономерностей

Логические закономерности следует искать для каждого образа отдельно. Для этого образ с номером $s (s = 1, \dots, k)$ назовем *первым образом*, а объединение всех остальных образов назовем *вторым образом*. Для любой конъюнкции можно определить по таблице данных \cup число объектов первого образа $N(1, S)$ и число объектов второго образа $N(2, S)$, на которых указанная конъюнкция истинна. $N(1)$ – число объектов первого образа, $N(2)$ – число объектов второго образа.

Конъюнкцию будем называть *логической закономерностью*, характеризующей первый образ, если выполняются неравенства:

$$\frac{N(1,S)}{N(1)} \geq \delta, \frac{N(2,S)}{N(2)} \leq \beta,$$

где δ и β некоторые параметры; $0 \leq \beta < \delta \leq 1$. Чем больше δ и меньше β , тем сильнее логическая закономерность.

Закономерности находим с помощью алгоритма поиска закономерностей в виде конъюнкций длины 1,2,3 и т.п. [2] С помощью данного алгоритма обнаруживаются все закономерности, характеризующие k образов.

При решении прикладных задач возникает следующая проблема: число закономерностей, построенных на одном и том же пространстве признаков достаточно велико, причём области истинности, соответствующие этим конъюнкциям, отличаются друг от друга небольшим числом попавших выборочных точек.

Возникает необходимость в резком сокращении числа закономерностей при минимальной потере информации, так чтобы области истинности, соответствующие этим закономерностям, наилучшим образом покрывали выборочные точки. Предлагается алгоритм выбора на каждом подпространстве наилучшей закономерности, которой соответствует наименьший объем области истинности, а также наибольшее число попадающих туда выборочных точек данного образа. Т.о. получаем новый список закономерностей.

Если число закономерностей получается достаточно большим и после этого преобразования (хотим получить 3-5 на образ), применяем другой алгоритм сокращения числа закономерностей, принимая во внимание следующую гипотезу: вероятность возникновения закономерности в виде конъюнкции большей длины меньше, следовательно более предпочтительны конъюнкции большей длины. Последовательно рассматривая закономерности, находим те, которые поглощаются более длинными конъюнкциями, и выбрасываем их из списка. Т.о. получаем новый список закономерностей. В докладе будет подробно рассказано о специфике перечисленных алгоритмов.

Анализ данных центра медицины катастроф

Имеется сводная информация по районам города Новосибирска и Новосибирской области. Для их описания используются характеристики, описывающие химически опасные объекты, расположенные на территории районов, взрывоопасные объекты, пожароопасные объекты, биологические объекты. Известна площадь районов, плотность населения, протяженность железных и автомобильных дорог. Предполагается, что эти характеристики каким-то образом влияют на другие показатели (суммарные за 2000, 2001, 2002 годы: 1) кол-во ЧС (ДТП), 2) число пострадавших в ДТП, 3) общее

число ЧС*, 4) общее число пострадавших**). Будем рассматривать каждый такой показатель (целевую переменную) отдельно. Для этого разбиваем объекты (районы) на группы, исходя из значений соответствующих целевых переменных, последовательно расставляя границы между соседними максимально отличающимися значениями. Внутри каждой группы объекты считаем принадлежащими одному образу.

Для построения математической модели объектов строятся логические закономерности. Закономерности представляют собой логические высказывания; связывая диапазоны значений нескольких характеристик (или указывая диапазон значений только одной) можно выделить из всех характеристик основные, существенным образом влияющие на значения той или иной целевой переменной (кол-во ЧС и т.д.).

Для иллюстрации метода приведем несколько закономерностей. Районы Новосибирской области (их 32) разделили на 2 группы; объекты, отнесенные к первой группе таковы: число ДТП от 0 до 8, число пострадавших в ДТП от 0 до 34, общее число ЧС от 1 до 14, общее число пострадавших от 2 до 69. Районы второй группы с числом ДТП от 21 до 29, числом пострадавших в ДТП от 113 до 188, общее число ЧС от 31 до 39, общее число пострадавших от 146 до 211.

Пример закономерности для первой группы районов:

(Площадь района от 66.88 до 22 050) и (Плотность населения от 0.81 до 15.92) и (Кол-во ХОО до 4). Закономерность объединяет 93% от общего числа районов данной группы. На объектах другой группы закономерность не выполняется.

Пример закономерности для второй группы районов:

(площадь поражения (природный газ) на ВОО от 0.02 до 0.17) и (Кол-во ПОО от 1 до 3) и (Кол-во ГСМ на ПОО от 14 994 до 251 504) и (площадь поражения (ГСМ) на ПОО от 0.04 до 0.44) и (протяженность автодорог от 56.50 до 98.50 км). Закономерность объединяет 100% от общего числа районов данной группы. На объектах другой группы закономерность не выполняется.

Литература

1. Лбов Г.С., Старцева Н.Г., Логические решающие функции и вопросы статистической устойчивости решений // Новосибирск, изд-во Института математики, 1999.

* включает суммарное число ЧС (ДТП; пожар, взрыв; инфекции; бандитизм; отравления)

** включает суммарное число пострадавших в ДТП; от пожаров, взрывов; инфекций; бандитизма; отравлений

2. T.I. Luchsheva, Construction of mathematical model for analysis of the anthropological data // Pattern Recognition and Information processing, Minsk, 2003

**Ориентирующая информация по оценке внутренней
структуры химических нитей на основе выходных
характеристик их механических моделей**

Е.Г. Маежов, В.А. Климов, В.А. Чайкин, А.Г. Усов
(Санкт-Петербург)

Сложный характер внутренних структур химических нитей не позволяет вычислять их макроскопические характеристики методами статистической физики. Поэтому представляют интерес альтернативные методы решения проблемы. Один из таких методов основан на изучении реакции нити на возбуждаемые в ней колебания. Непосредственными и глубоко изученными аналогами этого метода являются методы сейсмической разведки и методы диагностирования трещин в металлических деталях[1]. В настоящей работе эти методы используются для идентификации структур реальных нитей и их механических моделей.

Изучается широкая система различных механических моделей внутренних структур химических нитей. На этой основе формируется база данных, определяющая взаимозависимости параметров моделей и параметров внешних механических воздействий на них с такими выходными параметрами, как модули упругости, характеристики релаксации, скорости распространения возмущений, меры затухания возмущений, дифракционные и интерференционные характеристики распространения возмущений.

Производится классификация моделей по их выходным параметрам. На основе классификации исходных данных об испытаниях реальных нитей в условиях, соответствующих расчетным условиям механических моделей, методами теории нечетких множеств [2] производится ориентировочная идентификация реальных (прецедентных) нитей и механических моделей.

Задача идентификации механической модели по наблюдаемым экспериментально свойствам реальной нити является, как это обычно для обратных задач, некорректной в смысле А.Н. Тихонова. Поэтому каждой реальной нити, в соответствии с имеющимся объемом экспериментальных данных о ее свойствах, может быть сопоставлен более или менее широкий класс механических моделей. В связи с этим разработана методика оценок возможной погрешности модельных расчетов при входных условиях, отличных от условий рассмотренных экспериментов.

Типичными представителями механических моделей изученного класса являются хорошо известные модели Фогта, Максвелла, Пойнтинга и другие модели, составляемые из элементов Гука, Ньютона и из пластических

элементов сухого трения. На основе развитого в [3] метода точного исследования продольных колебаний нитей, основанного на одновременном использовании лагранжевых и эйлеровых координат сечений нити, для различных моделей получены дифференциальные уравнения в частных производных для определения движений нитей. Методом разделения переменных получены частные решения этих уравнений и найдены формулы для вычисления скоростей распространения продольных волн в различных моделях.

Сравнение указанных формул указывает на принципиально различные роли, играемые в различных моделях такими основными характеристиками моделей, как вязкость и упругость их элементов. Так, например, в (модельной) нити Фогта скорость волны убывает, если возрастает вязкость ее элементов. В случае нити Максвелла ситуация противоположна. Обнаружились и значительные различия моделей и в характере зависимости скоростей распространения волн от их длины. В этом отношении нити Фогта и Максвелла также проявляют противоположные свойства. Рассмотрение более сложных моделей обнаруживает сложные зависимости скоростей распространения волн от характеристик моделей и от параметров волн. Это же можно сказать и о характере затухания волн.

Сравнивая проведенные модельные расчеты с экспериментальными данными, можно утверждать, что деформационные характеристики широких классов реальных нитей могут имитироваться механическими моделями, имеющими подходящим образом подобранные структуры. Это обстоятельство позволяет внутренним структурам реальных нитей сопоставить структуры механических моделей.

Поскольку базы знаний о структурах моделей и о структурах реальных нитей формируются в форме дескрипций этих структур, возникают затруднения в формировании рационально метризованных или, хотя бы, только топологизированных пространств, содержащих эти структуры в качестве своих элементов и позволяющих судить о близости этих структур. В настоящее время, по-видимому, наиболее рациональное сопоставление моделей и реальных нитей может быть реализовано путем проведения геометрических и физических аналогий между структурами моделей и описаниями структур реальных нитей [4].

Литература

1. Романов В.Г. Обратные задачи математической физики. М.: Наука, 1984. 264 с.
2. Романов В.Е., Климов В.А., Саакян Р.Р. К развитию информационных технологий в области технологии химических волокон // Вестник Санкт-Петербургского государственного университета технологии и дизайна. СПб.: СПГУТД, 2001. - № 5. С. 95-109.
3. Чайкин В.А. Основы механики нити. СПб.: СПГУТД, 1998. 126 с.

4. Зябицкий А. Теоретические основы формирования волокон. М.: Химия, 1979. 504 с.

**Осредненные параметры приведенных структур
химических нитей с учетом взаимодействия элементов
структур в единой нити**

Е.Г. Маежов, Р.Р. Саакян, В.А. Чайкин, А.Г. Усов, И.А. Шпехт
(Санкт-Петербург, Благовещенск)

При ограниченном числе показателей, характеризующих потребительские свойства нитей, можно указать различные по своим физико-химическим и структурным свойствам нити, которые, тем не менее, будут эквивалентны в отношении указанных потребительских свойств. Это обстоятельство открывает возможность для осреднения характеристик многообразных внутренних структур нитей с целью выделения минимального числа параметров, характеризующих эти структуры и определяющих с требуемой полнотой и точностью качество нити.

Рассмотрена возможность теоретического описания процесса деформирования нитей, надмолекулярная структура которых представляется осредненным образом, как состоящая из трех, вообще говоря, многосвязных областей: области плотного кристаллического построения макромолекул, межкристаллической аморфной области и межфибриллярной аморфной области. Для создания математических моделей таких нитей, в качестве промежуточного этапа, используются механические модели, в которых кристаллиты заменяются упругими элементами, межкристаллитная и межфибриллярная компоненты заменяются, соответственно, вязкоупругими и пластическими элементами. Различия в геометрии расположения указанных областей отражаются в различных способах соединения указанных элементов и значениями характеризующих их параметров.

Устойчивость и надежность построенных на основе анализа предлагаемых механических моделей алгоритмов расчета потребительских свойств нитей не вызывает сомнений в случае нитей достаточно большого диаметра, когда осредненные по поперечным сечениям количественные оценки отдельных компонент не зависят от выбора сечения. Однако в случае нитей малого диаметра сечения могут значительно отличаться одно от другого по своим структурным характеристикам [1]. При этом устойчивые классификации нитей по их потребительским свойствам могут производиться только при условии, что будет приниматься во внимание чередование структурных компонент нити в продольном направлении.

Сравнение теоретических и экспериментальных результатов, выполненное с помощью созданной в СПГУТД установки для регистрации характеристик прохождения в реальных нитях высокочастотных и

импульсных сигналов, указывает на возможность классификации нитей по их модельным аналогам.

Литература

1. Зябицкий А. Теоретические основы формирования волокон. М.: Химия, 1979. 504 с.

Полнота и плотность алгебры нейронных сетей в пространстве задач - основа приложений распознавания и нейронных сетей в биологии и медицине

Вл.Д. Мазуров, Л.Н. Юрченко. Н.В. Кисляк.

(Екатеринбург)

Введение

Искусственная нейронная сеть в данной статье - это ориентированный взвешенный граф, имеющий входы и выходы. В вершинах графа - алгоритмы (или функции, или преобразования) называемые формальными нейронами. Они перерабатывают входы в нейрон в его выходы. Выходы нейронов - входы в другие нейроны. На входы графа поступают условия решаемой задачи, в выходах графа - реакция нейронной сети на задачу. Связи между нейронами имеют веса, на вес умножается выход нейрона. Настройка весов, их подбор, служат тому, чтобы на выходе нейронной сети была информация о решаемой задаче. Можно настраивать и сами нейроны, это дает большие возможности для обучения нейронной сети на требуемую реакцию. Сама задача настройки сети есть оптимизационная задача или сводима к таковой, это трудоемкая задача, многоэкстремальная, и для ее качественного решения в случае большой размерности полезны генетические алгоритмы, которые нужно для большей эффективности распараллеливать. А идея распараллеливания - это опять-таки идея нейронной сети.

Задача есть пара [условия задачи; решение задачи].

Приведем неформальные утверждения, которые потом уточним и докажем

формально:

Утверждение 1: Для каждой задачи существует нейронная сеть, преобразующая

условия задачи в ее решение.

Это - теорема «полноты» нейронных сетей.

Утверждение 2: Для каждой задачи и для любой как угодно малой ее окрестности («близких» к ней задач) существует нейронная сеть, лежащая в этой окрестности, то есть осуществляющая отображение: условия задачи → решение задачи.

Это - теорема «плотности» нейронных сетей.

Доказательства этих теорем рассмотрим:

1) для дискретного случая (когда ответ задачи - в классе конечных слов над конечным алфавитом);

2) для непрерывного случая - когда условия задачи - элемент линейного пространства, а ответ лежит в другом линейном пространстве.

Дискретный случай

Так как в качестве решений рассматриваются конечные слова над конечным алфавитом, то можно, не нарушая общности, полагать, что выходное слово представлено в двоичном алфавите, затем для каждой буквы слова построить свою нейронную сеть, и затем объединить сети, построенные для всех букв.

Таким образом, вопрос сводится к построению нейронной сети с одним выходом, на котором появляются только символы 1 и -1.

Тогда утверждение 1 в уточненном виде - это теорема существования комитетов для аффинных задач дискриминантного анализа. Реализацией будет слоистая нейронная сеть, нейроны - линейные пороговые функции. Тогда для реализации решений любых задач нам нужны либо множества сетей, включающие слоистые, либо сети с подсетями, имеющими слоистое строение. Во втором случае нам достаточно веса дуг, связанных с нейронами, не входящими в слоистую подсеть, сделать нулевыми.

Непрерывный случай

Теорема полноты в этом случае - это теорема Колмогорова о представлении непрерывной функции многих переменных в виде суперпозиции непрерывных функций одной переменной. Это тоже отвечает слоистым сетям.

Пусть $C(X)$ - алгебра функций, непрерывных на ограниченном замкнутом множестве X из R^n . В этом случае плотность слоистых нейросетей с непрерывными нелинейными преобразованиями вместо сигнума вытекает из теоремы о плотности в $C(X)$ подалгебры, разделяющей точки X и замкнутой относительно унарного нелинейного преобразования.

Нейронные сети в моделировании системно -воспалительного ответа организма

Авторами построена система решающих правил диагностики и прогнозирования факторов системно - воспалительного ответа организма на факторы окружающей среды. Эта работа подтверждена рядом патентов Российской Федерации на соответствующие решающие правила. Следует сказать, что важна сама выдвигаемая авторами концепция системно - воспалительного ответа, отраженная в публикациях в центральных медицинских журналах.

Работа выполнена при поддержке РФФИ (проект 03-01-00241).

Методы выравнивания освещенности и контрастирования изображений

В.Л. Матросов, Е.Г. Перепелицин, С.М. Кулясов
(Москва)

Рассмотрим модель исходного изображения в виде суммы исходной локальной освещенности (ИЛО) и исходной фоно-объектовой составляющей (ИФО) [2]:

$$ИИ(i, j) = ИЛО(i, j) + ИФО(i, j), \quad i = \overline{0, m-1}, \quad j = \overline{0, n-1},$$

где m и n - размеры изображения.

Для получения синтезируемого изображения (СИ), в смысле визуального восприятия и повышения информативности, каждая составляющая аддитивной модели подвергается преобразованию, т.е.

$$СИ(i, j) = \Phi(ИЛО(i, j)) + F(ИФО(i, j)), \quad i = \overline{0, m-1}, \quad j = \overline{0, n-1}.$$

Уточнение характера информационного содержания составляющих позволяет определить процедуру получения синтезируемого изображения:

$$СИ(i, j) = \Phi(ИЛО(i, j), \Delta_1, \dots, \Delta_r) + F(ИФО(i, j), \mathcal{G}_1, \dots, \mathcal{G}_q),$$

где $i = \overline{0, m-1}, j = \overline{0, n-1}$, Φ - процедура преобразования ИЛО, K - оконтуривание ИФО, F - контрастирование, $\Delta_1, \dots, \Delta_r, \mathcal{G}_1, \dots, \mathcal{G}_q$ - параметры соответствующих преобразований. Задача преобразования изображения заключается в нахождении оптимального набора параметров в смысле некоторого критерия качества, формализующего понятия улучшение визуального качества и повышение информативности изображения.

Исходная локальная освещенность является основой математической модели изображения. Уточнение специфики информации, которая должна быть сосредоточена в исходной локальной освещенности, позволяет сделать вывод о характере преобразования при построении данной составляющей и о применении метода локально-несмещенного сглаживания [1]. Преобразования данного метода позволяют сформировать исходную локальную освещенность с требуемым информационным содержанием и, что немаловажно, в соответствии с психофизиологическими основами функционирования зрения.

Основное назначением исходной локальной освещенности состоит в формировании своего аналога – опорной локальной освещенности (ОЛО), используемого при синтезе преобразованного изображения. Предлагаемый метод выравнивания освещенности позволяет преобразовать ИЛО в ОЛО с целью перевода освещенности всех фрагментов изображения в удобный для восприятия диапазон интенсивности яркости при помощи функции:

$$ОЛО(i, j) = \left(\frac{127 - \Delta}{127} \right) (ИЛО(i, j) - 127) + 127, i = \overline{0, m-1}, j = \overline{0, n-1},$$

где m и n - размеры изображения.

Формирование ИФО в виде разности исходного изображения и исходной локальной освещенности позволяет поставить задачу контрастирования объектов на изображении. Получение улучшенного аналога ИФО – контрастированной фоно-объектовой составляющей (КФО), предполагает возможность применения преобразования. Функция преобразования простого контрастирования будет иметь следующий вид:

$$КФО(i, j) = \begin{cases} k \cdot ИФО(i, j), & \text{если } |ИФО(i, j)| \leq \delta, \\ \text{sign}(ИФО(i, j)) k \delta \mu \sqrt{\frac{|ИФО(i, j)|}{\delta}}, & \text{если } |ИФО(i, j)| > \delta, \end{cases}$$

где $i = \overline{0, m-1}, j = \overline{0, n-1}, m$ и n - размеры изображения.

Параметры k и δ задаются априори. Степень корня μ подбирается экспериментально при заданных значениях k и δ .

Литература

1. Горелик В. А., Кулясов С. М. *Локально-несмещенная фильтрация изображений* // Сборник научных трудов «Моделирование, декомпозиция и оптимизация сложных динамических процессов». – М.: ВЦ РАН, 2002. – С. 25 – 30.
2. Кулясов С. М. *Общие принципы преобразования изображений в целях улучшения их визуального качества* // Материалы научно-практического семинара «Новые информационные технологии: материалы шестого научно-практического семинара» / Моск. гос. ин-т электроники и математики. – 2003. – С. 24-25.

Компьютерные методы виброакустического прогноза

С.А. Махортых, А.Р. Гатина, С.А. Костарев, С.А. Рыбак

(Пушино, Москва)

Постановка задачи вибро-акустического прогноза и способы ее решения

Задачи прогнозирования вибро-акустической обстановки в городских условиях достаточно актуальны в силу многообразия действующих источников, среди которых не последнее место занимают линии метрополитена. Колебания стен тоннеля, возникающие при движении железнодорожного состава, передаются в окружающий грунт и по нему распространяются на значительные расстояния, оказывая нежелательное воздействие на людей, аппаратуру и оборудование, вызывая смещения

зданий и сооружений, приводя, в отдельных случаях, к разрушениям. Таким образом, низкочастотная вибрация (1 – 100 Гц), может оказывать негативное воздействие на экологическую обстановку, вызывая «акустическое загрязнение» среды. По этой причине величины (уровни) вибрации являются нормативными параметрами, значения которых учитывают при строительстве наземных зданий и прокладке транспортных магистралей. В этом смысле контроль эмиссии упругих волн подземными источниками является важной экологической проблемой.

Будем рассматривать модель тоннеля в виде тонкой упругой цилиндрической оболочки толщиной h и радиусом R , помещенной в безграничную идеальную жидкость. К внутренней стороне оболочки приложено динамическое давление $p_0(x, \varphi, t)$. Требуется определить величину суммарного звукового поля во внешней среде, на основе анализа его модового состава. Будет показано, что учет сдвиговой упругости грунта в первом приближении достаточно производить только при расчете реакции грунта на обделку.

Решение получаемой системы ищется в виде

$$u = (u_1 - u_2 \sin \varphi - u_3 \cos 2\varphi + \dots) e^{i(k_x x - \omega t)}$$

для оболочки и

$$p = (p_1 H_0^{(1)}(kr) + p_2 H_1^{(1)}(kr) \sin \varphi + p_3 H_2^{(1)}(kr) \cos 2\varphi + \dots) e^{i(k_x x - \omega t)}$$

для поля во внешней среде.

На основе данного разложение построено уточненное решение, учитывающее простую конечно-элементную модель среды (рассматривается три типа линейной стратификации – приповерхностный канал, минимум скорости звука на глубине h , скорость звука возрастает с глубиной).

Программа VibraCalc

На основе предлагаемого метода разработана программа VibraCalc (новая версия ранее применявшейся программы UNSONIC). Пакет реализован в интегрированной системе. Вызов соответствующих операций осуществляется путем выбора пунктов меню или подменю. Результат представляется в графическом и текстовом форматах на экране терминала или выводится на принтер. Исходные модули пакета написаны на языке C++. Примеры расчетов тоннеля прямоугольного сечения приводятся на рисунках 2 – 3. Результаты расчетов по модифицированной версии и с использованием прежней версии программы Unsonic отличаются на величину 0 – 3 дБ для различных типов стратификации и случаев взаимного расположения источника и экрана (рассматриваются характерные для задачи расстояния до 50 м от источника).

Алгоритм и программа протестированы в многочисленных расчетах для Московского, Санкт-Петербургского и Екатеринбургского метрополитенов.

Проводимые исследования выполняются при финансовой поддержке РФФИ (проекты 01-02-16127, 01-07-90317, 00-01-05000), проекта 107 6-го конкурса молодых ученых РАН.

Vibra
Calc 1.2

РИС. ЗНАЧЕНИЯ УРОВНЯ ВИБРОУСКОРЕНИЯ НА ПОВЕРХНОСТИ ГРУНТА
1 - X-компонента, 2 - Z-компонента (63.0Гц)

Предельно допустимая норма вибрации (ночь) 32 дБ
Результат расчета:
Уровень виброускорения превышает норму на расстоянии от 0 до 39 м от тоннеля

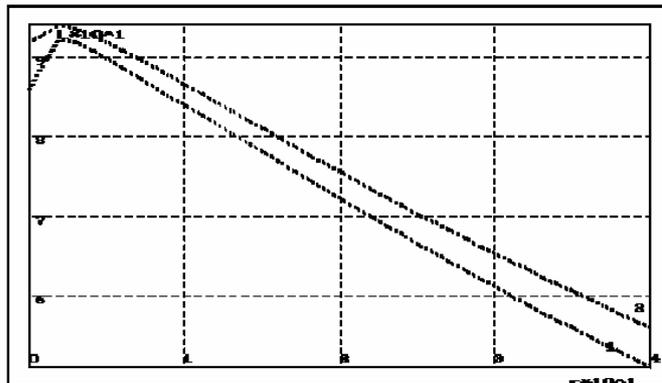


Рис.2. Зависимость уровней вибрации от расстояния до тоннеля.

Vibra
Calc 1.2

РИС. ЗНАЧЕНИЯ УРОВНЯ ВИБРОУСКОРЕНИЯ НА ПОВЕРХНОСТИ ГРУНТА
1 - X-компонента, 2 - Z-компонента (63.0Гц)

Предельно допустимая норма вибрации (ночь) 32 дБ
Результат расчета:
Уровень виброускорения превышает норму на расстоянии от 0 до 39 м от тоннеля

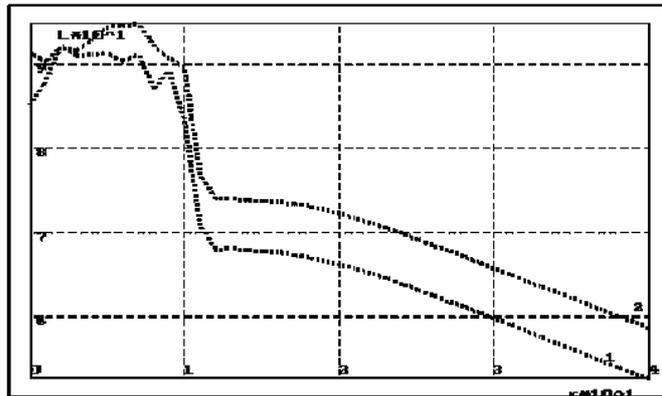


Рис. 3. Зависимость уровней вибрации от расстояния до тоннеля с использованием виброизолирующего экрана.

Литература

1. Ландау Л.Д., Лифшиц Е.М. Теория упругости. М.: Наука, 1987.
2. S.A.Kostarev, S.A.Makhortykh, S.A.Rybak. Calculations of ground vibrations induced by underground sources: analytical and numerical approaches. – In Noise and vibration from high-speed trains. London, Thomas Telford Publishing, 2001.
3. Музыченко В.В., Рыбак С.А. Низкочастотное рассеяние звука ограниченными оболочками. Обзор. Акустич. ж. Том 34, вып. 4, с. 561 - 577.
4. Ф.Ф.Дедус, С.А.Махортых, М.Н.Устинин, А.Ф.Дедус. Обобщенный спектрально-аналитический метод обработки информационных массивов. М.: Машиностроение, 1999.

Восстановление следа пера при анализе сканированных рукописных документов

Л.М. Местецкий, А.Г. Нефедов

(Тверь)

Редукция задачи Off-line распознавания к задаче on-line распознавания

Ввиду того, что эффективность для систем on-line распознавания гораздо выше, чем у систем off-line распознавания, возникает идея преобразования off-line информации к on-line сигналу, т.е. восстановления динамической информации из статической [1]. После этого становится возможным применение on-line методов распознавания, которые значительно эффективнее. Отсюда возникает задача восстановления следа пера (ВСП), которая составляет основную трудность такого перехода.

Поиск последовательности точек, упорядоченных по времени, правдоподобно описывающих реальную траекторию движения пера при письме, на основе анализа сканированного рукописного документа, представляет собой задачу ВСП.

Работа выполнена при поддержке РФФИ, проект 02-01-00667.

Штриховый граф

Для решения задачи ВСП предлагается математической модель следа пера основанная на штриховом графе.

Штрих – это модель элемента письма (палочка крючок кружок и т.д.)

Предлагаемый подход основывается на построении штрихового графа, отражающего структуру рукописного слова, определяются правила, по которым задается метрика графа. Путь минимального веса, проходящий через все вершины на графе, выбирается в качестве следа пера.

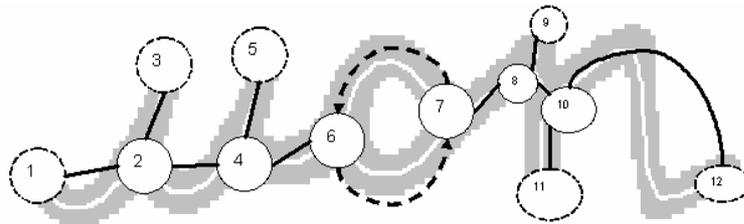


Рис. 1 Штриховой граф.

Предложенный метод построения штрихового графа, основан на скелетном представлении растрового изображения [2].

Метрика штрихового графа

Метрика штрихового графа основывается на гипотезе о гладкости. Гипотеза о гладкости - это предположение, о том, что человек в процессе написания штрихов не допускает резких изменений направления и скорости движения пера. Резкие изменения происходят, как правило, лишь в терминальных точках и связаны с прямым и обратным ходом пера, а также при наличии циклов и связаны с обходом цикла и последующим отрывом пера.

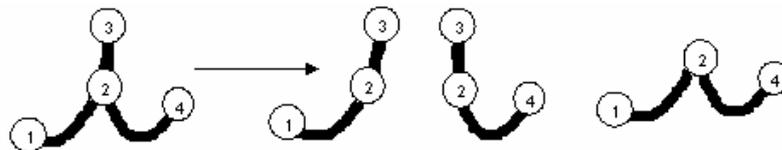


Рис. 2 Гипотезы движения пера в узле графа.

Для узлов штрихового графа строятся гипотезы возможного движения пера в узле графа. Гипотезы строятся как всевозможные объединения любых двух штрихов, входящих в узел. Вычисляется степень изгиба штриха образованного гипотезой. Строится весовая матрица переходов, в которой вес перехода - это степень изгиба штриха.

Вычисление степени изгиба штриха

При вычислении степени изгиба штриха приходится решать некоторые задачи, такие как учет локальной гладкости штриха, учет гладкости оси штриха и границы. Для вычисления степени изгиба штриха предложен следующие методы: выравнивание штриха вдоль границы (Рис.3), аппроксимация штриха жирными линиями (Рис.4), вычисление кривизны жирной линии.

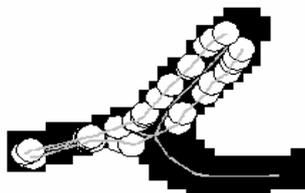


Рис. 3 Выравнивание штриха вдоль границы.

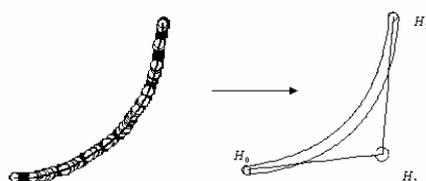


Рис. 4 Аппроксимация штриха жирной линией.

Выравнивание представляет собой изменение (вытягивание) осевой линии скелета в соответствии с границей штриха. Аппроксимация штриха жирными линиями представляет собой подгонку жирной кривой Безье [3] к выровненному штриху. Кривизна жирной линии определяется как кривизна ее оси.

Поиск пути на штриховом графе

Для восстановления следа пера необходимо найти путь минимального веса, проходящий через все вершины штрихового графа. Такой поиск сводится к решению задачи коммивояжера. Для поиска пути на штриховом графе, разработан однопроходный алгоритм с выделением и анализом циклов. Алгоритм получает приближенное решение задачи коммивояжера.

Для алгоритма поиска пути была построена классификация циклов, возникающих на штриховых графах. Алгоритмы обхода циклов основываются на предложенной классификации циклов по количеству узлов. В процессе поиска пути при попадании в вершину, принадлежащую циклу, такая классификация позволяет правильно обойти цикл.

Заключение

Для проведения вычислительных экспериментов была создана программная модель системы ВСП. Оценка правильности ВСП производилась на основе визуального контроля при помощи анимации движения пера.

В процессе экспериментов построена классификация ошибок, связанных с некорректным восстановленным следом пера. Проведенные эксперименты позволяют оценить качество алгоритмов ВСП на уровне экспертных оценок.

Для получения более полных оценок предполагается подключение системы on-line распознавания.

Литература

1. Lallican P.M., Viard-Gaudin C., Kneer S. From Off-line to On-line Handwriting Recognition // Seventh International Workshop on Frontiers in Handwriting Recognition. September 11-13, 2000, Amsterdam.
2. Местецкий Л.М. Непрерывный скелет растрового изображения // Графикон - 98, Москва, МГУ, 1998.
3. Местецкий Л.М. Компьютерная графика на основе жирных линий // Графикон -2000, Москва, МГУ, 2000.

Непрерывная гранично-скелетная модель дискретного изображения с контролируемой точностью аппроксимации

Л.М. Местецкий, И.А. Рейер

(Москва)

При решении задач анализа и распознавания формы изображений широко применяются граничное (контурное) и скелетное [1] представления объектов.

Традиционный подход к построению таких представлений основан на применении определенных алгоритмов непосредственно к дискретному изображению [2]. И граница, и скелет при этом представляются либо в виде “линий” на растре шириной в один пиксел, либо в виде непрерывных ломаных, аппроксимирующих эти растровые линии. Достоинством такого подхода являются относительные простота и эффективность алгоритмов построения представлений. Однако в этом случае приходится адаптировать границу и скелет, изначально непрерывные конструкции, определяемые для непрерывных областей, к геометрии регулярных точечных пространств, в терминах которой формулируются растровые алгоритмы [3].

Другой путь к построению границы и скелета растрового образа состоит в аппроксимации его некоторой «непрерывной» замкнутой областью и построении скелета этой области [4]. В частности, можно использовать полигональную область, поскольку для построения ее скелета существуют эффективные алгоритмы [5,6,7].

Однако и в этом случае возникает проблема неоднозначности вычисления скелета. Скелет чрезвычайно чувствителен к локальным свойствам границы образа. Две области, имеющие несущественные для глаз различия границы, например, за счет шумов, могут иметь принципиально различные в смысле топологической структуры скелеты. Вместе с тем, сравнительный анализ этих скелетов показывает, что в них присутствуют общие ветви, которые и определяют фундаментальные свойства структуры образа. Возникает необходимость отделить эти существенные элементы

скелета от несущественных, определяемых шумовыми эффектами. Решение этой задачи обычно осуществляется путем «стрижки» скелета, т.е. отсечения несущественных ветвей. При этом явные критерии определения существенных и несущественных элементов скелета не формулируются, и отсечение осуществляется на основе эвристических правил [8]. В результате не может быть оценена точность вычисленных скелетов.

Авторы предлагают корректный критерий выделения существенных элементов скелета, а также метод, реализующий такое выделение. Идея решения этой задачи состоит в следующем. Определим для каждой замкнутой области некоторую \mathcal{E} -окрестность – множество всех замкнутых областей, отличающихся от исходной не больше чем на заданную величину \mathcal{E} в хаусдорфовой метрике. Элемент скелета области будем считать существенным, если он присутствует (т.е. имеет близкие элементы) в скелетах всех областей, входящих в эту окрестность. Практический результат, который мы хотим получить – это метод определения существенных элементов в скелете области, составляющих так называемый базовый скелет этой области. Таким образом, мы рассчитываем найти ту скелетную конструкцию, которая характеризует фундаментальную структуру исходного объекта (изображения), инвариантную относительно способа аппроксимации этого объекта.

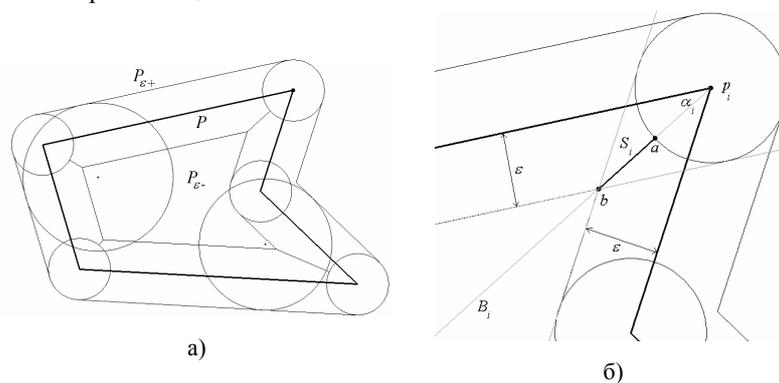


Рис. 1.

Пусть P – некоторая полигональная область, а \mathcal{E} – некоторое положительное число. Базовый скелет области определим с использованием следующих конструкций.

Будем называть \mathcal{E} -расширением $P_{\mathcal{E}+}$ полигональной области P объединение P и замкнутой \mathcal{E} -окрестности границы области P (рис. 1а).

Пусть α_i – некоторый выпуклый угол полигональной области P , B_i –

биссектриса этого угла. Рассмотрим a – точку на B_i , удаленную от вершины угла на ε , и b – точку пересечения прямых, параллельных сторонам угла и находящихся на расстоянии ε от сторон угла (рис. 1б). отрезок ab будем называть шипом выпуклого угла α_i . ε -сужением $P_{\varepsilon-}$ области (рис. 1а) будем называть объединение множества всех точек области, лежащих вне ε -окрестности границы, и шипов всех выпуклых углов области.

Круг C будем называть максимальным ε -допустимым кругом для P (рис. 1а), если: (1) $H(P, P \cup C) \leq \varepsilon$; (2) $H(\partial P, \partial(P \cup C)) \leq \varepsilon$; (3) C не содержится целиком ни в каком другом ε -допустимом для P круге. Нетрудно показать, что множество центров максимальных ε -допустимых кругов для P совпадает со скелетом области – множеством центров максимальных лежащих в области P кругов.

Круг C будем называть базовым кругом для полигональной области P , если выполнено следующее: (1) C является максимальным ε -допустимым кругом для P ; (2) пересечение C с $P_{\varepsilon-}$ не содержится целиком ни в одном максимальном ε -допустимом для P круге, не совпадающем с кругом C . Множество центров всех базовых кругов для P будем называть базовым скелетом P , $MA_{base}(P)$. Базовый скелет является подмножеством скелета области P .

Справедлива следующая

Теорема: Пусть Ω – некоторая область, хаусдорфово отклонение которой от P не превышает ε . Тогда через δ -окрестность каждого ребра базового скелета, где $\delta = \varepsilon / \cos^2(\alpha/2)$, α – угол между сайтами границы P , биссектором которых является данное ребро; будет проходить ветвь скелета области Ω , максимальные круги которой касаются сегментов границы Ω , проходящих через ε -окрестности сайтов границы P .

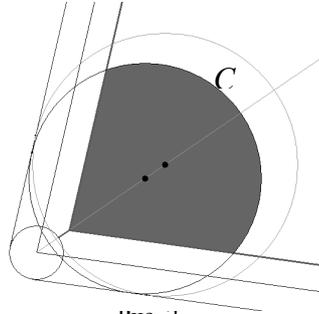


Рис. 2.

Следовательно, можно говорить, что каждое ребро базового скелета аппроксимирует некоторую ветвь скелета любой \mathcal{E} -близкой P области с точностью δ . Если же взять δ_{\max} – максимальное из всех таких δ , то базовый скелет можно рассматривать как аппроксимацию существенной части скелета любой \mathcal{E} -близкой P области с точностью δ_{\max} .

Теперь рассмотрим, каким образом можно выделить в скелете аппроксимирующей полигональной области базовый скелет. Нетрудно видеть, что базовый круг с центром на бисекторе пары сайтов, образующей выпуклый угол, не должен иметь пересечений с \mathcal{E} -окрестностью вершины угла, то есть должен пересекать соответствующий шип (рис. 2). В противном случае круг не был бы базовым. Соответственно, возникает следующая идея построения базового скелета: надо двигаться от терминальных вершин скелета по ребрам вглубь области, “стирая” ребра, и при этом смотреть, как ведет себя максимальный \mathcal{E} -допустимый круг с центром в точке, в которой мы находимся. Если круг пересекает какой-нибудь шип, то процесс “стирания” останавливается.

Предлагаемый метод, в отличие от существующих, предоставляет теоретическую основу для “стрижки” скелета с контролируемой точностью. Применение базового скелета в качестве “существенной” части дает практический метод такой “стрижки”. Тем самым появляется возможность построения информативного непрерывного скелетного представления для бинарного растрового изображения. При этом непосредственное построение скелета аппроксимирующей полигональной области может быть осуществлено любым из известных методов, а дальнейшая стрижка с контролируемой точностью – с помощью предложенного метода.

Работа выполнена при поддержке Российского Фонда фундаментальных исследований (РФФИ), проект 02-01-00667.

Литература

1. Blum H. A transformation for extracting new descriptors of shape. Models

- for the Perception of Speech and Visual Form, pp. 362-380. MIT Press, 1967.
2. Lam L., Lee S.-W., Suen C. Y. Thinning methodologies: A comprehensive survey. IEEE Trans. PAMI, 14(9), Sept 1992.
 3. Старовойтов В. В. Локальные геометрические методы цифровой обработки и анализа изображений. Минск, 1997.
 4. Местецкий Л. М. Векторизация бинарных растровых изображений на основе аппроксимации // Доклады X Всероссийской конференции «Математические методы распознавания образов» (ММРО-10). Москва, 2001. С. 249-252.
 5. Kirkpatrick D. G. Efficient computation of continuous skeletons. In 20th Annu. Symp. Found. Computer Sci., pp. 18-27, 1979.
 6. Lee D. T. Medial axis transformation of a planar shape. IEEE Trans. PAMI, PAMI-4, No. 4, Jul 1982.
 7. Местецкий Л. М. Непрерывный скелет бинарного растрового изображения // Труды межд. конф. "Графикон-98". Москва, 1998.
 8. Shaked D., Bruckstein A. M. Pruning medial axes. Computer Vision and Image Understanding, Vol. 69, No. 2, 1998, pp. 156-169.

Логическое программирование агентов для поиска и распознавания информации в Интернет

А.А. Морозов
ИРЭ РАН, Москва

Агентами Интернет называют программы, автоматизирующие поиск, распознавание, извлечение и анализ информации в Сети, ориентированные на нужды конкретного пользователя (или группы пользователей).

Одним из наиболее интересных и перспективных подходов к программированию агентов Интернет является логическое программирование агентов [1,2]. Актуальность этого подхода определяется, в частности, соответствием идеологии и принципов логического программирования задачам поиска, распознавания и анализа неструктурированной, плохо структурированной, а также гипертекстовой информации [5,6,7]. В последнее десятилетие было разработано большое количество подходов и методов логического программирования агентов Интернет, основанных на различных модификациях и расширениях языка Пролог, а также неклассических логиках (линейной, модальной и др.) [1,2]. Тем не менее, до сих пор не был создан математический аппарат, который обеспечивал бы свойства корректности и полноты логических программ (агентов), работающих в динамическом внешнем окружении (т.е. в условиях постоянного изменения и пополнения исходной информации в Интернет). Для решения этой проблемы мы разработали математический аппарат, основанный на принципе повторного доказательства подцелей.

1. Идея математического аппарата

Созданный математический аппарат логического программирования агентов Интернет включает:

1. Модель агентов, работающих в динамическом внешнем окружении.
2. Декларативную семантику агентов.
3. Стратегии исполнения агентов Интернет, обладающие корректностью и (при определённых условиях) полнотой относительно декларативной семантики этих агентов.

В рамках разработанной модели, агент Интернет (а также набор взаимодействующих агентов Интернет) описывается с помощью логической программы, исполняемой под управлением специальной стратегии, реализующей так называемые повторные доказательства подцелей.

Идея повторных доказательств состоит в том, что программа разделяется на подцели (названные «логическими акторами») [4,5], обладающие следующими свойствами:

1. Единственным каналом обмена информацией между акторами являются общие переменные.
2. Доказательство акторов может осуществляться в произвольном порядке, независимо друг от друга.
3. Результаты доказательства любого актора можно отменить, оставив без изменения другие подцели программы.

После отмены результатов доказательства актора, оно может быть осуществлено повторно. Тем самым, можно реализовать модификацию проведённых рассуждений. Результаты вычислений и сам ход рассуждений могут быть частично изменены во время и после окончания логического вывода. Это позволяет, в частности, приводить логические рассуждения в соответствие с новой информацией, поступающей извне.

2. Системы логических акторов и декларативная семантика агентов

Наиболее сложной и интересной задачей, возникающей при таком представлении агентов, является разработка стратегий управления, поддерживающих повторные доказательства и при этом обладающих математическими свойствами корректности и (желательно) полноты.

В качестве одной из первых была создана стратегия последовательного исполнения логических программ с логическими акторами. Эта стратегия подробно описана в [4], там же доказаны теоремы о корректности этой стратегии и её полноте при отсутствии зацикливаний программы.

Дальнейшие эксперименты с визуальным программированием агентов показали целесообразность разработки параллельных стратегий управления. В настоящее время мы расширили нашу модель, введя в неё параллельные процессы. Каждый процесс является системой логических акторов; процессы взаимодействуют с помощью асинхронных сообщений [5].

Важным свойством логической программы является то, что она обладает

теоретико-модельной семантикой [5,6]. С помощью теоретико-модельной семантики можно оценить такие свойства программы как:

1. Корректность алгоритма. Разработанная стратегия управления гарантирует, что программа никогда не вычислит (некорректные) значения, не принадлежащие её теоретико-модельной семантике.
2. Полнота алгоритма. При выполнении определённых условий мы можем гарантировать полноту логической программы. Это означает, что программа реализует исчерпывающий перебор и находит все существующие решения поставленной задачи.

3. Реализация и практическое использование

На основе созданного математического аппарата разработан параллельный объектно-ориентированный логический язык Акторный Пролог (новые версии определения языка см. на сайте [3]). В настоящее время мы ввели в язык средства получения информации по HTTP и FTP, а также средства компонентного визуального программирования на основе SADT (Structured Analysis and Design Technique) диаграмм [5].

В настоящее время реализован действующий прототип системы логического программирования агентов Интернет на основе разработанного математического аппарата и языка Акторный Пролог.

Заключение

Разработан математический аппарат логического программирования агентов, осуществляющих поиск и распознавание информации в сложно структурированной, динамической среде Интернет. В основу разработанного математического аппарата положен принцип повторного доказательства подцелей, позволяющий модифицировать логические рассуждения, приводя их в соответствие с новой информацией, поступающей извне.

На основе разработанного аппарата модифицируемых рассуждений создан параллельный объектно-ориентированный логический язык Акторный Пролог.

Я благодарен д.ф.-м.н. Ю.В. Обухову, который является соавтором проекта, а также акад. РАН Ю.И. Журавлёву и проф. МГУ В.А. Захарову за плодотворное обсуждение проблемы описания декларативной семантики многоагентных систем.

Работа выполнена при поддержке РФФИ (грант 03-01-00256).

Литература

1. Sadri F., Toni F. Computational Logic and Multiagent Systems: a Roadmap. – 1999. (<http://citeseer.nj.nec.com/sadri99computational.html>)
2. Davison A. Logic Programming Languages for the Internet // A. Kakas, F. Sadri (editors), Invited Submission for Computational Logic: From Logic Programming into the Future. – Springer Verlag, 2001. (<http://fivedots.coe.psu.ac.th/~ad/papers/summBob.ps.gz>)
3. Морозов А.А., Обухов Ю.В. Акторный Пролог. Определение языка

- программирования. – Москва, 1996. – Препринт ИРЭ РАН 2(613). – 57 с. (<http://www.cplire.ru/Lab144/index.html>)
4. Морозов А.А. Логический анализ функциональных диаграмм в процессе интерактивного проектирования информационных систем: Дисс. на соиск. уч. ст. к.ф.-м.н. – М., 1998. – 199 с. (<http://www.cplire.ru/Lab144/auto.html>)
 5. Morozov A.A., Obukhov Yu.V. An Approach to Logic Programming of Intelligent Agents for Searching and Recognizing Information on the Internet // Pattern Recognition and Image Analysis. – 2001. – Vol. 11. – No. 3. – pp. 570-582. (<http://www.cplire.ru/Lab144/pria570m.pdf>)
 6. Морозов А.А., Обухов Ю.В. Разработка математического аппарата логического программирования интеллектуальных агентов Интернета // Искусственный интеллект. – 2002. – N 4. – С. 580-587. (<http://www.cplire.ru/Lab144/ai2002.pdf>)
 7. Morozov A.A., Obukhov Yu.V. Development of the Methods and Tools for Mathematically Correct Logic Programming of Internet Agents // Pattern Recognition and Image Analysis. – 2003. – Vol. 13. – No. 2. – pp. 225-227. (<http://www.cplire.ru/Lab144/pria225.pdf>)

Об одном методе построения скелетов объектов изображения

С.А. Мустафин

(Алматы)

При создании баз данных проблемной геоинформационной системы, как правило, в качестве исходных данных используют существующие топографические и тематические картоматериалы. Ввод и формирование на их основе цифровых карт осуществляется средствами технологии, базирующейся на сканировании карт и их последующей векторизации. От возможностей обеспечиваемого качества результата и скорости программных средств векторизации в значительной степени зависит и производительность применяемой технологии в целом. В свою очередь, процесс векторизации растрового изображения включает в себя и скелетизацию (утончение) изображения, т.е. выделение линейчатой структуры, по которой непосредственно строится векторное представление исходного объекта изображения.

С другой стороны, развитие лингвистических способов распознавания образов и методов построения баз данных изображений делает актуальной разработку алгоритмов автоматического выделения структурных элементов (признаков) изображений. В качестве таких элементов часто используется геометрические и топологические особенности изображений: дуги, контуры, концевые точки пересечения и разветвления линий и другие. Относительно

новым подходом является выделение структурных элементов на основе скелета (контура) изображения, в котором сохраняются основные геометрические и топологические характеристики исходного изображения.

После ввода графического изображения в компьютер большинство линий, составляющих изображение и имеющих разную толщину, приобретает размытый вид. Такое качество изображения не позволяет применять к нему известные методы по выделению тех или иных графических примитивов, в то время как глаз легко адаптируется к чрезмерной толщине и неровностям линий. В связи с этим для выделения остовов кривых, несущих основную информацию об их форме и взаимосвязях, такое изображение обычно подвергают утончению. К операции утончения сводится и задача сжатия информации - минимизации объема видеoinформации, например, картографической информации: выделение линейных образований на изображениях земной поверхности (дороги, реки и т.п.), границ областей с нечетко выраженными очертаниями (степные массивы, урбанизированные территории, побережья морей, озер и т.п.). При значительном протяжении линейных структур применяется режим прослеживания. Фактически утончение соответствует удалению излишней информации без потери сущности и связанности элементов изображения. Таким образом, утончение можно отнести к первому этапу обобщения информации в автоматическом распознавании изображений. На следующих этапах с помощью некоторых преобразований можно достичь степени абстрагирования, достаточной для ведения понятий графических примитивов с соответствующими параметрами, набор которых, по сути дела, является входным для процедур распознавания [1,2].

Предлагаемый нами алгоритм утончения основан на развитии идеи хорошо зарекомендовавшего себя алгоритма классификации. Он не относится ни к одному из известных алгоритмов утончения и является примером алгоритма итерационного типа, который не использует понятия контурных точек, а отслеживает изображение по линиям в определенном направлении и рассматривает средние точки для каждого момента времени, которые и составляют остов (скелет) изображения линии. Данный алгоритм имеет сходство с неитерационным алгоритмом утончения, который использует средние точки сечения.

Разработка метода прошла апробацию в рамках темы «Создание автоматизированной системы обработки картографической информации» и показала хорошую эффективность для бинарных изображений. Метод выделения осевой линии на изображении применим для горно-геологических задач, в задачах проектирования вскрышных работ, когда требуется определить направление проведения работ по выемке минерального сырья и максимально приблизиться к требуемым условиям по содержанию минералосодержащих компонент.

Многие методы распознавания, предложенные для решения некоторых научно-технических задач, с той или иной степенью адаптации применяются к объектам, далеким от этих задач. Например, методика работы с картографическими материалами может быть трансформирована для понимания изображений, связанных с кровеносными сосудами, сетью нервных волокон, дерматоглификой, сетью дорог по фотографиям, полученным с большой высоты и т.п.

Определение скелетов (контура) изображений может найти успешное применение при решении различных практических задач: анализ структуры кровеносных сосудов глаза, обработка картографической информации и космических снимков, разделение перекрывающихся частей объекта, анализ формы объекта, нахождения серединной линии в отпечатках пальцев, задачи сегментации изображения, распознавание рукописных знаков, архивация данных изображения и т.д.

Литература

1. Айдарханов М.Б., Мухамедгалиев А.Ф. Алгоритмические основы построения систем классификации. Алматы, 1999., 101 с.
2. Мустафин С.А. Методика определения близости плоских кривых // Новости науки Казахстана, научно-технический сборник, 2002г., вып.4, с.51-55.

Геоинформационные технологии в задачах обновления цифровых картографических данных

А.Ф. Мухамедгалиев, А.А. Мухамедгалиев
(Казахстан)

Основу геоинформационных систем и технологий составляет векторная цифровая карта, позволяющая проводить топологическую взаимосвязь топографических объектов и их атрибутивных описаний в базе данных. Векторное представление картографических данных представляет широкие возможности для масштабирования, редактирования и обновления как топографических, так и других тематических слоев, отражающих состояние природных и техногенных территориальных процессов.

Рассмотрим задачу обновления цифровой топографической карты с использованием данных дистанционного зондирования.

Пусть $T(X,Y)$ – цифровая топографическая карта исследуемой территории, X,Y – система географических координат, $G(X,Y)$ – космическое изображение, нормализованное по системе координат X,Y к топографической карте $T(X,Y)$, $P(X,Y)$ – новый топографический объект на $G(X,Y)$.

Определение 1. Матрица $M = \|m_{ij}\|_{qxL}$, $m_{ij} = 0,1$ называется

геоинформационной матрицей или отображением топографического объекта $P(X,Y)$ на топографическую карту $T(X,Y)$, если условные координаты $i_1, \dots, i_v, j_1, \dots, j_w$ ее единичных элементов соответствуют географическим координатам $X_1, \dots, X_v, Y_1, \dots, Y_w$ объекта $P(X,Y)$.

Сформулируем основную задачу обновления Z_N .

Задача обновления Z_N состоит в построении алгоритмической модели обновления $Q(A_1, \dots, A_t)$ такой, что ее применение к топографическому объекту $F(P)$ на космическом снимке $P(X,Y)$ дает геоинформационную

матрицу $M = \|m_{ij}\|_{qxL}$.

Дальнейшая работа по обновлению картографических данных будет состоять в построении набора алгоритмов A_1, \dots, A_t , составляющих модель $Q(A_1, \dots, A_t)$, последовательной применение которых к космическому изображению $G(X,Y)$ дает полное решение основной задачи обновления Z_N .

Опуская обзор и анализ существующих алгоритмических моделей цифровой обработки данных дистанционного зондирования, здесь мы приведем полный состав алгоритмов A_1, \dots, A_5 модели обновления $Q(A_1, \dots, A_5)$.

АЛГОРИТМ	НАИМЕНОВАНИЕ АЛГОРИТМА	РЕЗУЛЬТАТ РАБОТЫ
A1	Алгоритм нормализации ДДЗ	Координатная привязка космического изображения $P(X,Y)$ к цифровой топографической карте $T(X,Y)$.
A2	Алгоритм классификации	Локализация на $P(X,Y)$ однородных территориальных комплексов
A3	Алгоритм медианной фильтрации	Подавление мелких площадных образований
A4	Алгоритм векторизации	Оконтуривание локализованных на $P(X,Y)$ однородных территориальных комплексов
A5	Интерфейс с ГИС	Перевод контуров однородных территориальных комплексов в форматы ГИС

В результате последовательного применения описанного семейства алгоритмов мы перенесем с космического изображения новые топографические объекты на цифровую картографическую проекцию в

автоматическом режиме.

Литература

1. Королев Ю.К., Баранов Ю.Б. Методы обработки данных дистанционного зондирования. Информационный бюллетень ГИС, N2(4), 1996, с.51-55.

Отслеживание движений животных с использованием 2D модели

Т.В. Мухина, И.Ю. Зарайская, К.В. Анохин

(Институт нормальной физиологии им. П. К. Анохина, Москва)

Введение

Видеотрекинг, то есть нахождение движения и поз животных по видеоизображению, является важнейшим методом автоматизации и унификации поведенческих экспериментов. Однако в существующих системах видеотрекинга и анализа поведения животных в основном используются такие параметры, как длина траектории, время (например, [1, 2]), а также динамические параметры (распределение линейных и угловых скоростей и ускорений по траектории [3]). Они характеризуют движение животного как материальной точки, не давая никакой информации о его позе. При этом теряется чрезвычайно важная информация о структуре поведения в терминах естественных биологических единиц (вид поведения, поза). К сожалению, до сих пор основное внимание при распознавании поз уделялось человеку [4], работ с животными очень мало.

Поэтому в данной работе предложен подход по анализу видеоряда поведения животного (мышь) с целью распознавания его поз. Он основан на разработанной авторами двумерной модели тела мыши и не требует нанесения маркеров на тело животного, что существенно расширяет его экспериментальную применимость.

Методика

Для получения видеоряда поведения мыши использовался тест по исследованию животным новой среды – квадратной платформы 10x10 см, приподнятой над полом на высоту 50 см. Съемка производилась в горизонтальной проекции (вид сверху), т.к. подобная конфигурация содержит наибольшую информацию о позе животного. Видеокамера располагалась на расстоянии 50 см выше платформы.

При создании модели особое внимание уделялось тому, чтобы модель, с одной стороны, учитывала анатомические особенности животного (в данном случае мыши) и, с другой стороны, обладала достаточно небольшим количеством степеней свободы. Наиболее существенными параметрами для понимания поз мыши являются основание хвоста, конец морды (нос) и углы сгиба в поясничном и шейном отделах. Была разработана кинематическая

геометрическая 2D модель тела мыши (рис. 1). Модель имеет 2 оси вращения в горизонтальной плоскости: 1 – поворот передней части тела (плечевой, шейный отдел и голова) относительно оси, заданной центрами окружностей, моделирующих заднюю и среднюю части тела (угол α_1); 2 – поворот шеи и головы (как целого) относительно плечевого пояса (угол α_2). Положение точки 1 (центр модели) совпадает с областью сгиба позвоночника в поясничном отделе скелета мыши, точки 2 – с началом шейного отдела, точки 3 – с тазовым отделом позвоночника, точки 4 – с основанием черепа. Параметры D_1 и D_3 характеризуют изменение длины тела при сгибе туловища в вертикальной проекции относительно оси A-A', D_2 – вытягивание в шейном отделе. Первоначальная ориентация модели и размеры ее частей определялись в процессе инициализации.

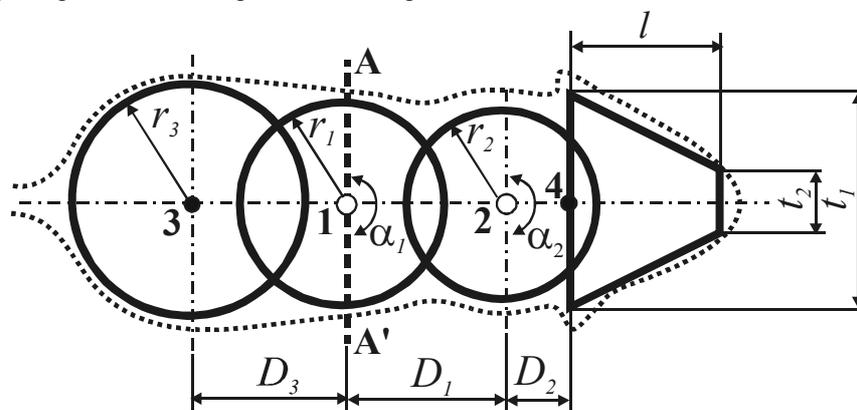


Рис. 1. Модель мыши.

Точками показан контур мыши.

Для каждого кадра осуществлялось выделение силуэта животного, выделение туловища и хвоста и последующая подгонка модели по туловищу. На этапе инициализации параметров модели (при обработке самого первого кадра) находили центр тяжести хвоста, положение которого позволяло определить общую ориентацию модели, а центр эллипса, аппроксимирующего контур туловища, принимали за центр модели (точка 1). После этого находились как постоянные (размеры составных элементов), так и переменные (углы и вытягивание) параметры модели. На всех последующих кадрах менялись расстояния D_1 , D_3 (как результат сгиба туловища относительно оси A-A'), D_2 , а также углы α_1 и α_2 . При обработке изображений использовалась библиотека OpenCV [5].

Результаты

Несмотря на простоту модели, она достаточно хорошо описывает изменение положения отдельных частей тела мыши в процессе движения и

позволяет найти голову и хвост, распознавать повороты тела и головы, а также некоторые виды поведения, например, исследовательское вытягивание. Примеры работы модели для нескольких кадров показаны на рис. 2.

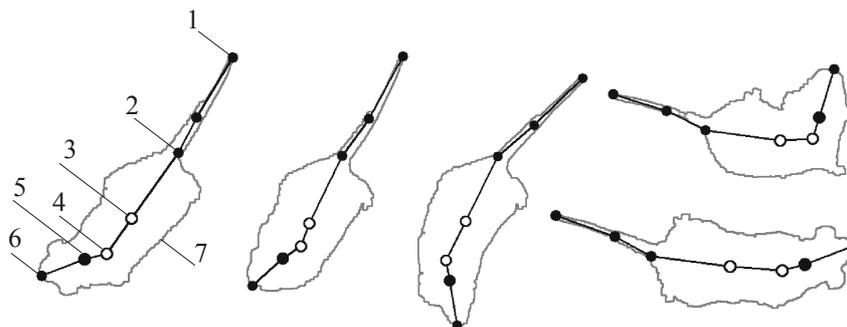


Рис. 2. Фрагменты трекинга движения мыши с использованием 2D модели.

1 – кончик хвоста, 2 – основание хвоста, 3 – точка сгиба в поясничном отделе, 4 – точка сгиба у основания шеи, 5 – основание черепа, 6 – нос, 7 – контур животного.

Имеющиеся проблемы можно разделить на два вида: оптические, связанные с обеспечением необходимого оптического контраста, и алгоритмические, связанные непосредственно с моделью. Первые решаются созданием более совершенной экспериментальной установки, вторые требуют усовершенствования модели (в частности, более детального распознавания вертикальных движений по горизонтальной проекции). Хотя ясно, как можно существенно поднять качество двумерной модели, тем не менее, магистральный путь – фиксация движений животного с нескольких точек зрения и построение более реалистичной трехмерной модели.

Литература

1. Noldus L.P. et al. Behavior Research Methods, Instruments & Computers, 2001, V. 33, 398-414.
2. Mukhina T.V. et al. Behavior Research Methods, Instruments & Computers, 2001, V. 33, P. 371-80.
3. T. V. Mukhina et al. Analysis of animal path trajectories in terms of individual behavioral acts // Abstr. 4th Int. Conf. on Methods and Techniques in Behavioral Research "Measuring Behavior 2002", 27-30 August, 2002, Amsterdam, The Netherlands, P. 177-178.
4. T. B. Moeslund and E. Granum. Computer Vision and Image Understanding, 2001, V. 81, P. 231-268.
5. <http://www.sourceforge.net/projects/opencvlibrary>.

Идентификация отказов измерительных модулей на основе функционального резервирования датчиков

А.А. Нижегородов, А.В. Шолохов

(Серпухов)

Введение

Рассмотрена проблема идентификации отказов измерителей систем управления подвижных объектов (СУПО) при уменьшении числа резервных датчиков. Эффект достигается за счет использования объективно существующих связей между выходными сигналами датчиков. Новые связи позволяют в реальном времени реализовать функциональное резервирование и отказаться от использования части резервных датчиков.

Предлагаемый подход обеспечивает уменьшение массы и габаритов измерительных модулей без снижения их надежности при работе систем управления подвижных объектов в реальном времени.

Информационные ресурсы, используемые при решении задачи идентификации отказов измерителей

Решение задач идентификации отказов измерителей предполагает наличие информационной (аппаратурной и алгоритмической) или временной избыточности [1]. В реальном времени чаще всего используют информационную избыточность, поскольку возможность применения временной избыточности (за счет проведения повторных измерений) ограничена вследствие большой скорости изменения во времени измеряемых параметров. Особенность измерительных модулей СУПО в том то, что измеряемые величины являются векторными и для их измерения применяют несколько одностепенных датчиков. При этом их входные оси ориентируют в заданных направлениях с целью создания измерительных базисов, обеспечивающих как высокую точность измерения векторной величины, так и возможность идентификации отказов. Для реализации последнего предусматривается аппаратная избыточность измерителей, которую определим в виде разности

$$m = n - n_{\min},$$

где n - общее число измерителей; n_{\min} - минимальное число, необходимое для создания измерительного базиса. Под измерительным базисом будем понимать множество трёх линейно независимых векторов, задающих ориентацию входных осей одностепенных датчиков.

В настоящее время широко применяется структурное резервирование, при котором входные оси основных и резервных датчиков параллельны. Достоинством такого подхода является простота реализации алгоритмов идентификации отказов. Однако необходимость использования в

сравнительно большого количества датчиков приводит к ухудшению массогабаритных показателей измерительных модулей.

Преимущество функционального резервирования связано с использованием измерительной информации не только с измерителей одного направления, но и с других направлений. Идентификация отказов в этом случае осуществляется с использованием уравнений связей между выходными сигналами всех измерителей [1-3].

Число измерительных базисов N и определяемая на его основе вероятность Q отказа модуля, включающего n измерителей, определяются при структурном и функциональном резервировании, соответственно, как [3]

$$N_C = n_1 n_2 n_3, \quad Q_C \approx 3 \cdot (3q_a + q_b)^2,$$

$$N_{\hat{O}} = \tilde{N}_n^3 = \tilde{N}_{m+3}^3, \quad Q_{\hat{O}} = 15q_a^4 - 24q_a^5 + 10q_a^6,$$

где n_i - количество измерителей с одинаковой ориентацией входных осей, q_a - вероятность отказа датчика; q_b - вероятность отказа вычислителя СУПО.

Приведем пример, иллюстрирующий преимущества функционального резервирования. Определим вероятности отказов двух измерительных модулей: модуль с девятью измерителями ($m = 6$) при мажоритарном способе идентификации отказа “два из трех”; модуль с шестью измерителями при функциональном резервировании [1]

$$Q_C \approx 3 \cdot (3q_a + q_b)^2; \quad Q_{\hat{O}} = 15q_a^4 - 24q_a^5 + 10q_a^6$$

Сравним оба варианта резервирования, используя отношение вероятностей для достаточно малых вероятностей отказов q_a

$$S = \frac{3(3q_a^2 - 2q_a^3)}{15q_a^4 - 24q_a^5 + 10q_a^6} \approx \frac{3}{5q_a^2}.$$

Таким образом, при структурном резервировании с мажоритарными схемами при $n = 9$ надежность даже ниже, чем при использовании функционального резервирования датчиков.

Разработка структур измерительных модулей

Для получения в аналитическом виде уравнений связей между выходными сигналами измерителей будем различать в структурах измерительных модулей основные и резервные датчики. Входные оси основных измерителей, обозначенные X, Y, Z , взаимно перпендикулярны в пространстве в отличие от осей резервных S_1, S_2, S_3 . Разработка структур измерительных модулей сводится к решению задачи определения ориентации входных осей резервных датчиков по отношению к основным.

Алгоритмы идентификации отказов для этих структур составляются в

виде комбинаций уравнений связей между выходными сигналами датчиков, которые в общем виде могут быть представлены, как

$$\left| C_1^D(\alpha_{i-j})y^p - C_2^D(\alpha_{i-j})y^o \right| \leq E_{\text{доп}} , \quad f = \prod_{k=1}^n x_k$$

где y^o , y^p – соответственно, матрицы измерений основных и резервных измерителей; $C_1^D(\alpha_{i-j})$ и $C_2^D(\alpha_{i-j})$ – обобщенные матрицы коэффициентов; $E_{\text{доп}}$ – матрица допустимых погрешностей измерений.

Таблица диагностирования отказов формируется путем введения логической переменной x_k , принимающей значение единицы при соответствии k -го уравнения связи допуском и значение нуля – в противном случае. Оценка технического состояния проводится с привлечением функции f : в случае $f=1$ измерительный модуль считается исправным, в противном случае – отказавшим, причем по коду определяется номер отказавшего измерителя.

В качестве примера приведём таблицу диагностирования для пяти ДПИ (таблица 1). Из таблицы видно, что может быть идентифицирован отказ любого (одного) измерителя из пяти, поскольку коды отказов взаимно различимы. Структура измерительного модуля СУПО в случае появления одного отказа позволяет осуществлять управление движением по четырем работоспособным датчикам, поскольку в их числе любые три имеют неколлинеарные и некомпланарные входные оси.

Таблица 1. Зависимость функции f от номера отказавшего измерителя

Номер отказавшего измерителя	Состояния выражения для f				
	x_1	x_2	x_3	x_4	x_5
1	0	0	1	0	0
2	0	0	0	1	0
3	0	0	0	0	1
4	0	1	0	0	0
5	1	0	0	0	0

Кроме этого, имеется возможность восстановления измерительной информации отказавшего измерителя, что позволяет исключить перестройку алгоритмов оценки измеряемого вектора в случае возникновения отказа.

Литература

1. Обнаружение изменений свойств сигналов и динамических систем./Под ред. М. Бассвиль, А. Банвениста. – М.: Мир, 1989.
2. Елифанов А.Д. Избыточные системы управления летательными аппаратами. - М.: Машиностроение, 1979.
3. Нижегородов А.А., Шолохов А.В. Повышение отказоустойчивости измерительных модулей систем управления подвижных объектов на

основе функционального резервирования датчиков./Измерительная техника. – 2001. – №11. – М.: Изд-во стандартов. – 72с., с.15.

Идентификация нелинейных моделей цветовоспроизведения

А.В. Никоноров, С.Б. Попов, В.А. Фурсов

(Самара)

В работе [1] рассматривалась задача идентификации линейной модели цветовоспроизведения при многокрасочной печати. В частности, исследовалась возможность применения принципа согласованности оценок. Показано, что для моделей этого класса удается снизить ошибку аппроксимации в десятки раз. В настоящей работе на основе принципа согласованности оценок строится общая схема и рассматривается пример идентификации нелинейной модели.

В пространстве спектральных коэффициентов отражения печатных оттисков (в дальнейшем называемых спектрами) эта задача формализуется следующим образом. Задан вид зависимости спектра смеси красок y от вектора искомых концентраций $\mathbf{c} = (c_i)$, $i = \overline{1, n}$ красок, входящих в смесь:

$$y = F(\mathbf{X}, \mathbf{c}, \xi), \quad (1)$$

где $\mathbf{X} = [\mathbf{r}_p^T, \mathbf{r}_{p1}^T, \mathbf{r}_{p12}^T \dots]$ – $N \times M$ -матрица, компоненты которой суть измеренные спектры заданных концентраций базовых цветов (\mathbf{r}_p – спектр отражения печатной основы, \mathbf{r}_{pi} спектр стопроцентной концентрации i -той краски, входящей в смесь, лежащей поверх основы), $\mathbf{c} = [c_1, c_2, \dots]$ искомый $N \times 1$ -вектор параметров модели, ξ неизвестный $N \times 1$ -вектор ошибок измерений.

Задана также количественная мера различия между цветами (цветовой контраст), определяемая как расстояние между точками, соответствующими цветам в цветовом пространстве Lab [2, 3]:

$$\Delta E = \sqrt{(\Delta L)^2 + (\Delta a)^2 + (\Delta b)^2}, \quad (2)$$

где $\Delta L = L_i - L_j$, $\Delta a = a_i - a_j$, $\Delta b = b_i - b_j$, а L_i, a_i, b_i , L_j, a_j, b_j – координаты i -го и j -го цвета соответственно. Качество модели (1) характеризуется величиной цветового контраста ΔE между реальным цветом красочной смеси и цветом, оцененным с использованием модели.

Задача заключается в нахождении параметров модели, обеспечивающих минимальное расстояние в пространстве Lab между реальным и рассчитываемым значением цвета красочной смеси:

$$\min_{\tilde{\theta}} \sqrt{((L - \tilde{L}(\mathbf{c}))^2 + (a - \tilde{a}(\mathbf{c}))^2 + (b - \tilde{b}(\mathbf{c}))^2)}. \quad (3)$$

Здесь (L, a, b) – координаты цвета, наблюдаемые на обучающей выборке, $(\tilde{L}, \tilde{a}, \tilde{b})$ – рассчитанные с использованием модели (1).

Проблема заключается в том, что задача оценки векторного параметра \mathbf{c} должна решаться по малому числу обучающих образцов. Связано это с отсутствием для большинства красок тестовых шкал для измерения спектров. При малом числе наблюдений статистические оценки параметров не вполне надежны. В настоящей работе оценки строятся на основе принципа согласованности, не требующего задания априорных вероятностных моделей.

Суть метода состоит в следующем. Из исходной системы (1) формируются подсистемы меньшей размерности, путем исключения из нее набора соотношений, соответствующих некоторой части наблюдений. Для каждой k -той подсистемы:

$$\mathbf{y}_k = F(\mathbf{X}_k, \mathbf{c}_k, \xi_k), \quad (4)$$

находится оценка \mathbf{c}_k . Далее среди них отбирается оценка, доставляющая минимум критерию взаимной близости. В работе [4] критерий задавался в пространстве искомых параметров. В данном случае для задачи идентификации нелинейных моделей цветообразования предлагается в качестве такой функции использовать критерий (3) – минимум цветового контраста. Особенность заключается в том, что стандартные формулы перехода от спектров к цветовым координатам заданы только для векторов спектральных коэффициентов с размерностями больше 32, поэтому критерий (3) рассчитывается для каждой оценки \mathbf{c}_k применительно к исходной системе.

Описанная двухэтапная схема оценивания параметров нелинейных моделей реализуется с использованием нелинейных методов оптимизации. В настоящей работе использовались известный квазиньютоновский метод оптимизации – метод Бройдена-Флетчера-Шано (БФШ) [5] и метод на основе генетических алгоритмов (ГА). Процедуры на основе ГА использовались также для перебора вариантов подсистем вида (4).

С использованием описанного подхода в работе решалась задача определения параметров модели цветообразования для системы краска-бумага на основе формулы Юла-Нейлсона [2]:

$$\mathbf{r} = (a_1 \mathbf{r}_p^{1/n} + a_2 \mathbf{r}_p^{1/n})^n. \quad (5)$$

Вектор параметров $\mathbf{c} = [a_1, a_2, n]$ определялся четырьмя способами. Использовались обычный БФШ метод и ГА непосредственно для исходной

системы. Кроме того, оба метода были реализованы в рамках принципа согласованности (ПС) оценок. Результаты исследований приведены в таблице. В первой строке ошибки аппроксимации алгоритмов БФШ и ГА и этих же алгоритмов в сочетании с принципом согласованности (ПС) оценок. Вторая строка таблицы демонстрирует возрастание вычислительной сложности при использовании принципа согласованного оценивания.

Зависимость (5) при условии размерности вектора \mathbf{r} 41×1 оказалась достаточно сложной для БФШ метода. В результате было получено решение, значительно отличающееся от нижней границы значений цветового контраста. Поиск оптимума с использованием ГА показал гораздо лучшие результаты.

Таблица. Ошибка аппроксимации и вычислительная сложность методов

Характеристики	БФШ	БФШ-ПС	ГА	ГА-ПС
ΔE	7.503	3.180	0.457	0.023
Число операций	12.500	1.900.000	16.000	170.000

Из таблицы видно, что применение принципа согласованности в обоих случаях приводит к уменьшению значения ошибки. При применении этого принципа в сочетании с ГА величина ошибки сравнима со значением погрешности измерений (для используемого измерительного оборудования - $0.02\Delta E$). Заметим также, что процедуры, построенные в рамках принципа согласованности оценок на основе ГА оказываются достаточно универсальными и могут применяться для отыскания экстремумов целевых функций произвольного вида.

Таким образом, применение принципа согласованности оценок позволяет уменьшить ошибку аппроксимации нелинейных моделей по сравнению с оценками на основе традиционных оптимизационных техник, однако достигается это за счет существенного возрастания вычислительных затрат.

Работа выполнена при поддержке Министерства образования РФ, Администрации Самарской области и Американского фонда гражданских исследований и развития в рамках российско-американской программы "Фундаментальные исследования и высшее образование" (BRNE) и РФФИ (гранты № 01-01-00097, № 03-01-00109)

Литература

1. Никоноров А.В., Попов С.Б., Фурсов В.А. Вычислительные аспекты реализации идентификации моделей цветовоспроизведения. // Известия СНЦ РАН том 4, №1 с. 67-73
2. Никоноров А.В., Попов С.Б., Сравнительный анализ моделей цветообразования при офсетной многокрасочной печати. // Компьютерная оптика 2002, №23. с. 79-83
3. Джадд Д., Вышецки Г. Цвет в науке и технике. М., Мир, 1978, 580 с.
4. Фурсов В.А. Проблемы вычисления оценок по малому числу наблюдений. // Тр. конф. "Математическое моделирование 2001",

- Самара, 13-16 июня 2001, с. 56-63.
5. Реклейтис Г., Рейвиндран А., Рэгсдел К. Оптимизация в технике. Т1 М., Мир, 1986, стр. 125-131

Распознавание и адаптация для дистанционного образования

А.Х. Нишанов, Ш.Е. Туляганов, О.Ж. Бобомуродов, М.Х. Худайбердиев

(Ташкент)

Развитие науки и техники, компьютерной технологии и их применение во всех отраслях народного хозяйства привело к большим изменениям и в образовании. В системе дистанционного обучения (СДО), при использовании электронного учебника в каком-то смысле место учителя заменяет компьютер и поэтому управление всеми процессами обучения осуществляет компьютер. Здесь педагог выступает в качестве эксперта по предметной области. При этом предъявляются новые требования к системе: интеллектуальность, гибкость, адаптивность при организации процесса обучения[1].

Известно, что СДО включает в себя модули адаптивного тестирования для осуществления эффективной оценки приобретенных знаний обучаемого, статистики и анализа результатов для определения дальнейшей стратегии, верификации и проверки компетентности тестов для оптимизации процесса тестирования, интеллектуальной поддержки тестов для учета и индивидуальности каждого пользователя.

Развитие и ввод национальных языков алфавитов во вновь образовавшихся независимых странах ставит новое дополнительное требование к инструментарию СДО, заключающееся в разработке модуля распознавания текстовой информации на национальных алфавитах [2].

Решение данной задачи можно разделить на несколько этапов:

- сканирование текстового документа;
- предварительная обработка полученного изображения на предмет улучшения качества;
- достижение правильной ориентированности изображения (т.е. строки текста на нем должны быть близкими к горизонтальности);
- локализация отдельных знаков на предмет анализа;
- получение линейного образа каждого знака;
- выбор эталонов сравнительного распознавания знаков;
- приведение линейного образа знака к форме эталонного;
- распознавание знака.

При этом ключевым фактором распознавания служит выбор эффективного набора эталонов знаков, формы которых имеют структуру в виде прямых отрезков, пересекающихся под прямым углом или 45° . Выбор этот обуславливается тем, что задача сравнения с таким эталоном и

приведение линейных образов к этой форме минимум на порядок уменьшает вычислительные затраты на сравнение образа знака с эталоном. А это, само собой разумеется, дает реальные предпосылки для решения вопроса автоматизированного распознавания сканограмм текстовых документов[1].

По окончании этапа распознавания текстовой информации определяется уровень знания обучаемого, производится оценка и по результатам данного анализа принимается решение о дальнейшей стратегии подачи знаний в СДО.

Каждый правильный ответ обозначается единицей, а неправильный нулем.

Оценка каждого ответа равна

$$a_i = \begin{cases} 1, & true \\ 0, & false \end{cases}$$

Множество ответов тестируемого определяется как

$$A_p = \sum_{l=1}^n a_l, \quad A_p \in S,$$

здесь, A_p – множество правильных ответов, заранее известных (все множество массива состоит из единиц);

S – множество результатов тестирования;

Тогда уровень знаний обучаемого определяется как

$$B = \frac{A_p}{S} \cdot 100\%$$

По этому критерию определяется D – классификация обучаемого

$$D = R_q(B)$$

R_q - разделяющая функция, $q=1,2,3$.

Определив степень усвоения обучаемым, система строит по этим критериям дальнейшую стратегию обучения по предметной области[3].

Литература

1. Попов Д.И., Подсистема адаптивного тестирования среды дистанционного обучения., Конгресс конференций ИТО-2002. <http://www.bitpro.ru/ИТО/2002/VI/VI-0-1009.html>
2. Нишанов А.Х., Худайбердиев М.Х., Раджабов С.С.(Ташкент). Об одном алгоритме распознавания узбекского машинописного текста//конференции ММРО-Х. Москва-2001

3. Журавлев Ю.И., Камилов М.М., Туляганов Ш.Е., Алгоритмы вычисления оценок и их применение, «Фан» Ташкент 1974 г. 119 с.

Компьютерная подсистема для статистической и интеллектуального анализа медицинских данных
Н.А. Новоселова, Б.А. Залесский, О.В. Красько, Н.М. Скриган, Е.Е. Сотикова, А.П. Сучкова, И.Э. Том
(Минск)

Введение

Повсеместная компьютеризация позволила медикам создать огромное количество баз данных, содержащих практические медицинские данные. Актуальным в настоящее время является обобщение знаний, содержащихся в этих базах данных для использования при принятии решений о диагнозе, курсе лечения или прогнозе исхода лечения. Традиционный ручной анализ данных повсеместно замещается эффективным автоматизированным анализом с использованием специальных компьютерных программ.

Общая структура компьютерной подсистемы

В ходе работы над проектом, связанным с анализом значимости прогностических факторов риска и их динамики в процессе лечения для выбора адекватной индуктивной терапии острых лейкозов у детей нами разрабатывается компьютерная информационная система для статистического и интеллектуального анализа медицинских данных. Она включает два основных модуля:

- статистический, реализующий ряд статистических методов анализа данных, таких как дисперсионный анализ, кластерный анализ, метод главных компонент, регрессионный анализ, линейный дискриминантный анализ и т.д. Данный модуль позволяет сократить размерность анализируемых факторов, отбросив зависимые между собой факторы, выявить тенденцию данных к кластеризации, а также классифицировать данные по выбранному выходному фактору.
- нейросетевой модуль, реализующий ряд известных сетей, таких как многослойный перцептрон (MLP) для задачи классификации, регрессионного анализа и линейного и нелинейного метода главных компонент, самоорганизующаяся сеть Кохонена (SOFM) для задачи кластеризации.

Интерфейс компьютерной системы анализа медицинских данных

Основное окно подсистемы представлено на рис. 1. В главном меню перечислены основные пункты, соответствующие методам работы с данными. Данные представлены в окне в виде скролируемой таблицы, в строках которой содержатся медицинские данные, соответствующие конкретному пациенту.

Далее выборочно рассмотрим отдельные элементы пользовательского интерфейса. Основное окно для реализации дискриминантного анализа данных представлено на рис. 2.

	sysno (1)	sex (2)	age (3)	m1 (4)	h1 (5)
1	1	1.000	63.000	10.000	70.000
2	2	1.000	42.000	7.000	72.000
3	3	1.000	41.000	3.000	73.000
4	4	0.000	57.000	6.000	73.000
5	5	1.000	35.000	9.000	73.000
6	6	0.000	48.000	10.000	73.000
7	7	1.000	43.000	4.000	74.000
8	8	0.000	27.000	1.000	75.000
9	9	0.000	56.000	12.000	76.000
10	10	0.000	33.000	1.000	77.000
11	11	0.000	37.000	4.000	77.000
12	12	0.000	58.000	9.000	77.000
13	13	1.000	21.000	2.000	78.000
14	14	1.000	71.000	2.000	78.000
15	15	0.000	66.000	6.000	79.000
16	16	0.000	35.000	7.000	79.000
17	17	0.000	31.000	10.000	79.000
18	18	1.000	35.000	3.000	80.000

Рис. 1. Основное окно компьютерной подсистемы анализа медицинских данных.

Рис. 2. Интерфейс для реализации метода дискриминантного анализа.

Перед тем, как выбрать метод дискриминантного анализа и пошагового дискриминантного отбора переменных необходимо задать фактор, отвечающий за принадлежность случая к соответствующему классу.

Одним из основных методов анализа данных в нашем проекте является контролируемое обучение. Основной задачей контролируемого обучения является применение обучающего алгоритма для получения классификационной модели. Входными данными обучающего алгоритма является множество помеченных информационных записей пациента $E = \{F_1, F_2, \dots, F_n\}$, каждая из которых состоит из значений ряда признаков и метки класса $D = \{D_1, D_2, \dots, D_m\}$, к которому пациент относится. Обучающий алгоритм использует множество помеченных примеров для порождения классификатора, который используется для классификации непомеченных случаев. Средством реализации данного метода в нашей подсистеме является нейронная сеть.

Для обучения сетей типа многослойный персептрон используются различные обучающие алгоритмы: обратного распространения ошибки, переменной метрики, на основе метода Гаусса-Зейделя для решения системы линейных уравнений (для двухслойной сети). На рис. 3 представлен интерфейс пользователя для построения нейронной сети.

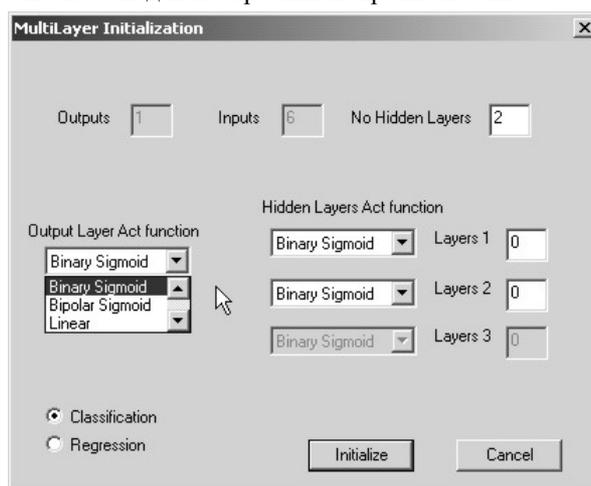


Рис. 3. Интерфейс для инициализации нейронной сети типа многослойного персептрона.

Результаты работы отдельных алгоритмов и задач сохраняются в стандартных файлах и отображаются в специальном окне для просмотра пользователем.

Заключение

Представлено краткое описание компьютерной программы, находящейся в стадии разработки и предназначенной для анализа медицинских данных с помощью различных статистических и интеллектуальных методов.

Дальнейшим развитием работы является реализация и включение в систему методов искусственного интеллекта, таких как деревья решений, байесовские сети доверия и генетические алгоритмы.

Программный комплекс для медицинской цифровой рентгенографии

М.М. Ольшовец, М.Н. Устинин, И.А. Никонов
(Пушино)

В Пуштинском научном центре РАН разработана цифровая компьютерная приставка к стандартному медицинскому рентгеновскому аппарату для получения рентгенограмм без применения рентгеновской пленки. В рамках проекта была создана компьютерная программа получения, просмотра, обработки, хранения и распечатки цифровых рентгеновских изображений. Аппаратно-программный комплекс в течение нескольких лет работает в клинических условиях в одной из сельских участковых больниц Московской области.

Принцип работы приставки следующий: рентгеновские лучи, проходя через объект, формируют теневое рентгеновское изображение. Попадая на люминесцентный экран, это изображение преобразуется в видимое, а затем проецируется на чувствительный элемент цифровой фотокамеры (ПЗС-матрицу). Здесь изображение регистрируется, оцифровывается и передается в компьютер для просмотра, обработки и хранения. Созданный программный комплекс объединяет в себе функции управления камерой, графического редактора и системы управления архивом цифровых снимков, сведений о проведенных обследованиях и личных данных пациентов.

Программа обеспечивает выполнение следующих задач.

1. Получение цифрового снимка, в том числе:

- настройку регистрирующего устройства на сеанс работы;
- возможность изменения оператором различных характеристик сеанса, таких, как время экспонирования кадра, количество оттенков в изображении, усиление, гамма-коррекция и т.д.;
- захват кадра с регистрирующего устройства.

2. Хранение снимков и организация быстрого доступа к ним, в том числе:

- возможность сохранения цифрового снимка на диске в стандартных общепринятых форматах хранения графических изображений;
- возможность считывания ранее сохраненного снимка для просмотра;
- ведение специализированной рентгенографической базы данных о пациентах, содержащей как графическую (снимки), так и различного рода текстовую информацию.

3. Визуализация снимков, в том числе:

- отображение кадров, захваченных с регистрирующего устройства, в главном окне программы;
- выбор активного кадра и его показ в отдельном полноэкранном окне.

4. Цифровая обработка снимков и печать на бумаге или пленке.

Снимки, полученные или обрабатываемые с помощью программы, записываются на диск в общепринятых графических форматах. Их просмотр и редактирование возможны также с помощью внешних графических редакторов. Основным форматом записи снимков был избран формат PNG (Portable Network Graphic), допускающий хранение снимков, полученных с различной глубиной оцифровки, возможна также работа в формате BMP (Device-Independent Bitmap) [1].

Малая контрастность получаемого снимка и повышенный уровень шумов являются серьезными препятствиями для цифровой обработки изображения.

Поэтому наиболее широкое применение в повседневной рентгенологической практике находят алгоритмы обработки изображения из класса алгоритмов поэлементной обработки, а также некоторые алгоритмы сглаживания. В частности, имеется возможность коррекции изображения по интерактивно задаваемой пользователем передаточной функции [5].

Еще один класс алгоритмов, который реализован в программе – свертка точек изображения малой области с матрицей коэффициентов, обычно прямоугольной или приближенно круглой формы. В состав программного комплекса включены шаблоны нескольких известных операторов свертки при различных размерах окна (гауссиан, лапласиан, фильтр Савицкого-Голца и др.) [5], пользователь может выбрать наиболее подходящую операцию, последовательно применять фильтры. Кроме того, пользователь может в диалоговом режиме сам задать произвольное окно и матрицу весов фильтра.

Также реализованы некоторые нелинейные алгоритмы обработки изображений со скользящим окном, такие, как медианная фильтрация, и фильтр, специально ориентированный на подавление точечных помех (выбросов) [2].

Наряду с шумоподавлением и повышением контрастности изображения важной задачей является задача сжатия цифровых рентгеновских снимков. Актуальность проблемы обусловлена необходимостью хранения большого числа полноформатных цифровых изображений и их передачи по компьютерным сетям. Для решения обеих задач использовались разложения по wavelet-базисам (базисам всплесков) [3], [4], представляющим собой специфические системы ортогональных функций, хорошо подходящих для обработки резко меняющихся данных. В отличие от упомянутых ранее алгоритмов, здесь снимок анализируется не как набор отдельных пикселей, а как совокупность строк или даже как двумерная кусочно-постоянная

функция.

Существуют эффективные алгоритмы быстрого преобразования исходного сигнала в пространство коэффициентов разложения [4]. Дальнейшая обработка цифровых массивов с использованием wavelet-базисов ведется в пространстве коэффициентов. Методы разложений по базисам всплесков ведут к экономному решению многих задач обработки, требующих реализации в рамках ограниченных аппаратных или вычислительных ресурсов. Уже появились и постепенно приобретают все более широкое распространение новые форматы графических файлов, использующие алгоритмы сжатия изображений, основанные на разложении по wavelet-базисам.

Вопрос определения качества восстановленного цифрового снимка при практической работе системы сводится к экспертной оценке врача-рентгенолога, поскольку существующие метрики, математически строго определяющие близость изображений, не вполне адекватны восприятию объектов глазом.

Проводимые исследования выполняются при финансовой поддержке РФФИ (проекты 01-07-97060, 01-07-90317, 01-01-00894).

Литература

1. Мюррей Д., У. ван Райпер. Энциклопедия форматов графических файлов: пер. с англ. – К.: Издательская группа BHV, 1997.
2. Розенфельд А. Распознавание и обработка изображений с помощью вычислительных машин: Пер. с англ. – М.: Мир, 1972.
3. Daubechies I. Ten Lectures on Wavelets. SIAM, Philadelphia, PA, 1992.
4. Mallat S. A Wavelet Tour of Signal Processing. Academic Press, Boston, 1998
5. Ross J. C. The image processing handbook. CRC Press, 1995.

Автоматизированное выделение объектов байкальских диатомей на РЭМ – снимках донных осадков

В.Ю. Павлов, В.Н. Сергеева, А.В. Тьков, Т.О. Железнякова

(Иркутск)

Введение

Озеро Байкал является древнейшим пресноводным водоемом мира и в его донных отложениях хранится летопись изменений климата за последние 20-30 млн лет. Одним из наиболее сильных и точных сигналов этой летописи является численность створок диатомовых водорослей, поскольку они хорошо сохраняются в осадках Байкала [1]. Распознавание вида створок и подсчет их численности осуществляется на основе изображений, полученных на сканирующем электронном микроскопе. Это утомительный и трудоемкий процесс, требующий высочайшей квалификации специалиста.

Даже визуальный анализ изображений затруднен из-за наличия шумов, несущественной для анализа информации, скученности объектов в разных местах изображения, их наложение друг на друга. В связи с этим возникла проблема автоматизации этого процесса.

Методы решения

Инструментом исследования был выбран Matlab. В качестве первого шага средствами этого пакета разработана программа, позволяющая сегментировать изображение, выделять объекты и рассортировывать их по различным признакам (площади, периметру, коэффициентам формы и т.д.). Идентификацию вида створок специалист в дальнейшем осуществляет визуально на основе отсортированных объектов. Даже этот вариант значительно облегчает процесс распознавания.

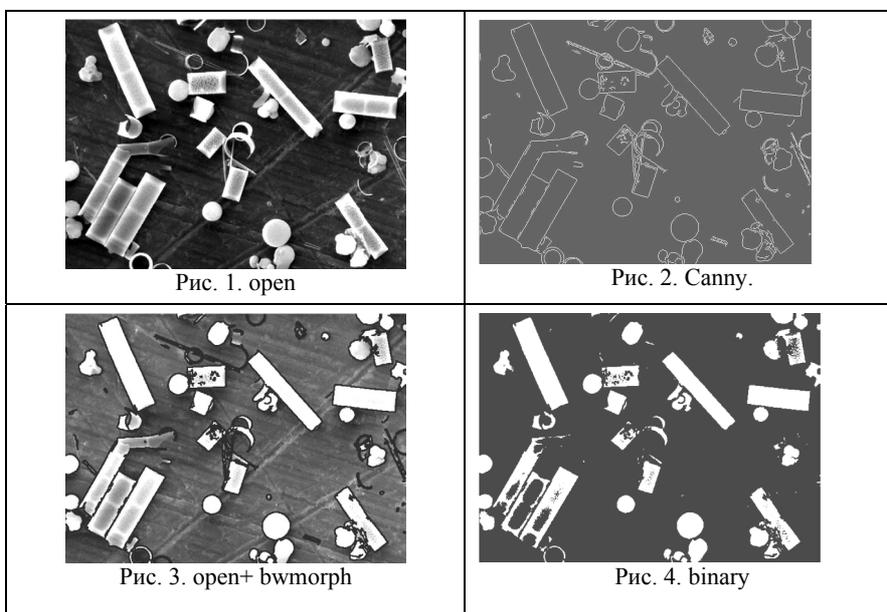
Графический файл с помощью стандартной функции (imread) считывается в матрицу, у которой количество строк соответствует высоте изображения в пикселях, количество столбцов – ширине, каждый элемент матрицы – яркость соответствующего пикселя изображения. Для иллюстрации выбрана небольшая часть фрагмента изображения чистой культуры (рис. 1.). Изображение всей пробы содержит около 1000 объектов.

Методом выделения границ (функция edge) выявляются перепады яркости на изображении методом Canny (рис. 2.). Для усиления эффекта разделения объектов границы утолщаются (функция bwmorph).

Далее на матрице исходного изображения зашумляются элементы соответствующие элементам матрицы границ (на исходном изображении эти точки становятся черными (рис. 3).

С целью применения методов поиска объектов, измерения признаков объектов осуществляется бинаризация изображения (функция im2bw). Порог бинаризации берется минимальным – 0.2-0.3 от максимальной яркости (рис. 4.).

Поиск объектов осуществляется функцией bwlabel, которая ищет на бинарном изображении связанные области пикселей объектов и создает матрицу: яркость пикселя 0 – фон; яркость пикселя i – пиксель, принадлежащий i-му найденному объекту.



Далее вычисляются признаки объектов (функция `imfeature`): обязательные для программы – `Area`, `ConvexImage` и `BoundingBox`; необязательные – признаки для сортировки объектов (площадь, периметр, коэффициенты формы и т.д.). Чтобы устранить из анализа изолированные точки и другие небольшие объекты, используется фильтр, убирающий объекты с площадью меньшей заданной пользователем.

В результате мы имеем: номер объекта; изображение (матрицу) "залитого" пикселями объекта выпуклого многоугольника, в который вписан объект – `ConvexImage`; координаты на исходном изображении выпуклого многоугольника, в который вписан объект, а также его размеры – `BoundingBox`. Иначе говоря, имеется вся информация, чтобы установить соответствие между найденными бинарными объектами и исходным изображением, а также выполнить сортировку (рис. 5.).

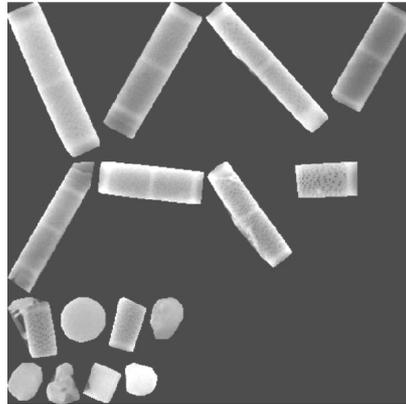


Рис. 5. sort

Результаты

Для сравнения результатов нами был проведен анализ серии изображений проб средствами известного пакета обработки изображений ImagePro и нашей программой. Нам удастся в большинстве случаев достаточно корректно автоматически разделять соприкасающиеся объекты. В ImagePro есть единственный способ это сделать – различные вариации с яркостью, контрастом и гамма-коррекцией, но при этих манипуляциях изображение в некоторых частях изменяется до неузнаваемости, во-первых, а во-вторых, это процесс исключительно ручной.

На этапах выделения границ и бинаризации теряется часть пикселей – на рис.4. видно, что объекты невыпуклые и с «дырами». Этот недостаток нам удастся устранить, что и видно на рис.5.

Пока нет автоматической настройки параметров используемых в программе функций (по умолчанию стоят параметры, при которых программа в большинстве случаев работает корректно);

В плане перспективы дальнейшей работы можно дальше развивать эту методику, а можно рассматривать данный метод как первый шаг в процессе распознавания образов.

Литература

1. Грачев М.А., Лихошвай Е.В., Воробьева С.С. и др. Сигналы палеоклиматов верхнего плейстоцена в осадках озера Байкал // Геология и геофизика, 1997, т.38, №5, с.957-980.
2. Потемкин В.Г., Инструментальные средства MATLAB 5.X. М., ДИАЛОГ-МИФИ, 2000.
3. Дьяконов В., Абраменко И. MATLAB Обработка сигналов и изображений. Специальный справочник. С-П., Питер, 2002.
4. Н. Н. Мартынов, А. П. Иванов MATLAB 5.X Вычисления, визуализация, программирование. М., ОЦ КУДИЦ-ОБРАЗ, 2000.

Моделирование переключения режимов биомагнитной активности мозга

Н.М. Панкратова, М.Н. Устинин, А.М. Молчанов

(Пушино)

Введение

Систему, имеющую два или больше режима функционирования, между которыми возможны переходы, называют мультистационарной. Примером системы переходящей из одного режима в другой является мозг человека. На записях ритмической активности мозга, снятой с поверхности головы, наблюдаются переходы между режимами при засыпании, пробуждении, исполнении различных задач. Так же наблюдаются вспышки патологического характера при некоторых нарушениях и болезнях (болезнь Паркинсона, эпилепсия и др.)

Цель настоящей работы состоит в том, чтобы построить математическую модель, которая могла бы адекватно описать переключения между физиологически нормальными и патологическими режимами, которые мы наблюдаем на экспериментальных данных магнитной энцефалографии (МЭГ) пациентов с болезнью Паркинсона и ее разновидностями. Были исследованы экспериментальные данные, полученные с помощью магнитометра Magnes 2500 WH, установленного в Центре нейромагнетизма медицинского факультета Нью-Йоркского университета. На экспериментальных данных мы можем выделить как минимум два резко отличных друг от друга режима:

1) колебания с высокой частотой и большой амплитудой;

2) колебания с низкой частотой и небольшой (по сравнению с первым случаем) амплитудой.

Первое соответствует патологической активности, второе – работе мозга, соответствующей норме.

Математическая модель

Для реализации переходов между разными режимами активности А.М.Молчанов предложил модель переключателя, которую для самого простого случая можно записать в виде системы (1):

$$\begin{aligned} \frac{dv}{dt} &= F(x,t)v(1-v) \\ \frac{dx}{dt} &= vA(x,t)+(1-v)B(x,t) \end{aligned} \quad (1)$$

где v - переменная, отвечающая за переключение, x - сигнал, который изменяется по закону $A(x,t)$, если $v=1$ или по закону $B(x,t)$, если $v=0$. В общем случае $A(x,t)$ и $B(x,t)$ задаются системами уравнений. Т.е. вводя в

систему знакопеременную функцию $F(x,t)$, мы получим переключение сигнала x из состояния $A(x,t)$ в состояние $B(x,t)$ и обратно.

Для моделирования сигналов, имеющих сходство с временным рядом МЭГ, нам подойдет система 3-го порядка - так называемый простой генератор шума КПР[3,7]. Области повышенной спонтанной кратковременной активности описываются автогенератором Ван-дер-Поля, который используют при моделировании различных патологий, когда нормальная активность сменяется четкими квазигармоническими колебаниями

Для параметрического переключения воспользуемся триггерной системой, которую в экологии используют для описания явления конкуренции между двумя видами[1,3]. Тогда математическая модель переключения между режимами запишется следующим образом:

$$\begin{aligned}
 \frac{dx}{dt} &= w(2hx + y - gz) + (1-w)(\gamma(1-y^2)x - y) \\
 \frac{dy}{dt} &= -wx + (1-w)x \\
 \delta \frac{dz}{dt} &= x - f(z) \\
 \frac{du}{dt} &= u - a_1uw - u^2 \\
 \frac{dw}{dt} &= w + a_2uw - w^2 \\
 \frac{da_1}{dt} &= a_2 \\
 \frac{da_2}{dt} &= -ra_1
 \end{aligned} \tag{2}$$

Параметры a_1 и a_2 изменяются таким образом, что узлы, находящиеся на осях фазовой плоскости (u,w) поочередно становятся устойчивыми, а переменная w принимает значение 0 или 1.

При изменении частотных характеристик системы, можно добиться сигнала, в котором соотношение между частотами и амплитудами режимов будет близко к экспериментальному соотношению. На рис.2 представлен такой сигнал.

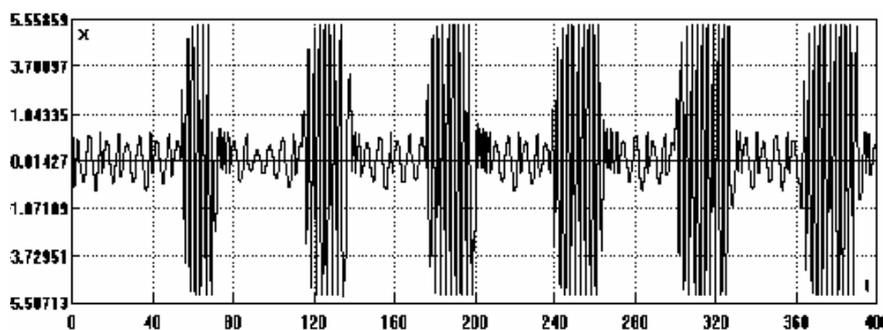


рис.2. Сигнал, имеющий сходство с экспериментальными данными по частотным характеристикам.

Построенная и исследованная в настоящей работе динамическая система (2) показала переключение между двумя различными режимами. Это переключение происходит без внешнего воздействия, как и в экспериментальном сигнале, т.е. получено самопроизвольное переключение между режимами. Гипнотерапевты [2] утверждают, что мозг может путешествовать по бесконечному числу собственных состояний. Эти состояния выглядят как аттракторы – области в фазовом пространстве, притягивающие фазовые траектории, где хаотические фазовые траектории ведут себя предсказуемым образом. Значит, чтобы мозг перешел из одного режима в другой, необходима дестабилизация стационарного состояния, в котором он пребывает в данный момент. Дестабилизация происходит посредством неоднозначности или при появлении вынужденного резонанса (гипнотизер понижает тембр голоса) [2]. В нашем случае внешнего воздействия на систему нет. Следовательно, дестабилизация происходит за счет внутренней неоднозначности. Роль неоднозначности играют параметры $a1$ и $a2$. Этим параметрам могут соответствовать концентрации ферментов или их соотношения. Изменяясь, параметры дестабилизируют существующее состояние равновесия и позволяют системе перейти от аттрактора, соответствующего нормальной работе мозга к аттрактору, соответствующему патологии. Дальнейшее изменение параметров дестабилизирует патологическое состояние и т.д. Полученный сигнал имеет близкие к эксперименту частотные характеристики. Проводимые исследования выполняются при финансовой поддержке РФФИ (проекты №№ 01-07-97060, 01-07-90317, 01-01-00894, 01-01-00893, 03-01-06271).

Литература

1. Ризниченко Г.Ю. Лекции по математическим моделям в биологии. Часть 1// Ижевск: НИЦ «Регулярная и хаотическая динамика»,2002.
2. Марк Е. Фурман, Марианна Риз. Исследования разума и мозга. Часть 1: Нейрофизика гипноза. // <http://www.humans.ru>

Методы регионального управления на базе алгоритмов экспертного и классификационного анализа

И.В. Покровская, Е.В. Бауман, А.А. Дорофеев, А.Л. Чернявский
(Москва)

Поставлена задача Управление региональными (территориальными) системами имеет целый ряд специфических особенностей, учет которых позволяет повысить эффективность управления. К таким особенностям, прежде всего, относится пространственное (территориальное) взаимодействие объектов, входящих в систему управления. Это транспортные, материальные, энергетические, миграционные и другие потоки между объектами - соседями; наличие на территории одного объекта межрегиональных предприятий или организаций, обслуживающих несколько соседних объектов (межрайонные больницы и диагностические центры, ТЭЦ, железнодорожные узлы, речные и морские порты и т.д.). Для управления подобными объектами была разработана компьютерная система “Аналитик” [1]. В системе “Аналитик” вся исходная информация (количественная, качественная, экспертная) об управляемых объектах (например, районы крупного города или области, субъекты РФ и т.д.) представляется в виде куба данных “объект-показатель-время”. В типовых задачах регионального управления приходится анализировать значения сотен показателей для десятков управляемых объектов и всё это для десятков моментов времени. Для качественного принятия решений в системе “Аналитик” используются специальные структурные методы анализа данных, позволяющие без существенных потерь производить “сжатие” такой информации. Для структуризации исходного набора показателей и получения так называемых интегральных показателей (число которых существенно меньше числа исходных) используются алгоритмы экстремальной группировки параметров [2]. Для структуризации объектов используются алгоритмы автоматической классификации (кластер-анализа) [3], как правило, классификация производится в пространстве интегральных показателей. Ввиду того, что задачи регионального управления относятся к классу слабоформализованных, для классификационного анализа данных в системе “Аналитик” возможно использование алгоритмов размытой экстремальной группировки и размытой автоматической классификации.

Результаты классификации объектов в системе “Аналитик” отображаются на цветной карте соответствующего региона, при этом пользователь может получить по каждому классу и по каждому объекту разнообразные статистические характеристики, а также траектории изменения во времени значений показателей и принадлежности объектов к классам.

Разработаны методы динамического классификационного анализа, позволяющие производить классификацию объектов в пространстве

траекторий, где каждая траектория - это набор значений показателя за выбранные моменты времени [4]. В результате получается небольшое число хорошо интерпретируемых типов (классов) динамических рядов (траекторий). Такая классификация существенно упрощает процедуру принятия управленческих решений, в частности вводится понятие “типовых решений” для соответствующих классов управляемых объектов.

Другой важный аспект задач регионального управления состоит в том, что значительная часть информации, используемой для принятия решений, является экспертной. Проведение экспертизы для получения такой информации имеет ряд особенностей, затрудняющих использование классических методов экспертизы. Для подобных случаев были разработаны методы коллективной многовариантной экспертизы [5]. Были сформулированы основные принципы коллективной многовариантной экспертизы:

- экспертиза проводится в экспертных комиссиях, число которых не меньше числа различных точек зрения на исследуемую проблему;
- в одну и ту же комиссию включаются эксперты, имеющие близкие точки зрения на проблему экспертизы;
- в каждой комиссии работают эксперты, не имеющие конфликтных взаимоотношений;
- для экспертизы отбираются условно компетентные эксперты;
- экспертиза проводится специальной консалтинговой группой, независимой и незаинтересованной в результатах экспертизы.

Эти принципы были реализованы в рамках специальной методики формирования экспертных комиссий. Методика включает 5 основных разделов (этапов): выявление кандидатов для работы в экспертных комиссиях; выявление существенно различных точек зрения; определение групп не конфликтующих экспертов; оценка условной компетентности экспертов; формирование экспертных комиссий. На этапах 2 и 3 существенно используются процедуры экстремальной группировки параметров, кластерного анализа и диагонализации матрицы связи [5].

Разработанные методы классификационного анализа и многовариантной экспертизы использовались при создании программно-алгоритмического обеспечения системы управления региональным здравоохранением в Новгородской области [6]. Объектами управления здесь были: либо районы и крупные города области, либо больницы, поликлиники и другие ЛПУ области (с их территориальной привязкой). Использовалось 156 исходных показателей. Для всех задач широко использовались интегральные показатели, доля которых в наборе параметров, по которым производилась классификация, составляла от 60 до 100%. Внедрение системы в Новгородской области позволило существенно повысить эффективность управления и снизить нагрузку на управленческий персонал.

Другое внедрение разработанной методологии было проведено в Московской области для системы управления пассажирским автотранспортом [7]. Для этой системы установлена связь структуры перевозок и структуры парка автотранспортных предприятий с показателями их экономической эффективности, доказана возможность управления структурой перевозок и структурой парка, разработаны варианты реформирования регионального холдинга (ГУП «Мострансавто»).

Разработанные методы дают руководству транспортного холдинга инструмент управления, позволяющий находить наиболее выгодную в данное время структуру перевозок; определять отстающие виды перевозок и разрабатывать стратегию их развития как по холдингу в целом, так и по отдельным предприятиям; определять приоритетные направления развития парка подвижного состава; своевременно фиксировать негативные тенденции в развитии отдельных предприятий и принимать меры по их устранению.

Разработанные методы являются достаточно универсальными и могут быть использованы для широкого класса региональных организационных систем, таких как жилищно-коммунальное хозяйство, энергоснабжение и другие.

Литература

1. Бауман Е.В., Дорофеюк А.А. Методика структурного анализа данных на базе системы “Аналитик” // Труды Института проблем управления РАН, том X, М.: ИПУ РАН, 2000, С. 30-37.
2. Браверман Э.М., Мучник И.Б. Структурные методы обработки эмпирических данных // М.: Наука, 1983. С. 464 .
3. Бауман Е.В., Дорофеюк А.А. Классификационный анализ данных // Избранные труды Международной конференции по проблемам управления, том 1.- М.: СИНТЕГ, 1999, С. 62-67.
4. Бауман Е.В., Дорофеюк А.А. Методы динамического классификационного анализа данных // Труды Института проблем управления РАН, том X, М.: ИПУ РАН, 2000, С. 6-11.
5. Дорофеюк А.А. Методы мультигрупповой многовариантной экспертизы в задачах анализа и совершенствования организационных систем // Труды Института проблем управления РАН, том X, М.: ИПУ РАН, 2000, С. 12-18.
6. Бауман Е.В., Дорофеюк А.А., Чернявский А.Л., Медик В.А. Классификационные методы в аналитических задачах регионального управления // Труды Института проблем управления РАН, том X, М.: ИПУ РАН, 2000, С. 38-39.
7. Дорофеюк А.А., Покровская И.В., Чернявский А.Л. Экспертно-классификационные методы анализа и совершенствования крупномасштабных организационных систем управления (на примере

регионального пассажирского автотранспорта) //Вторая международная конференция по проблемам управления. Тезисы докладов, том 2, М.: ИПУ РАН, 2003, С. 36.

Классификационные и экспертные методы в задаче определения оптимальных ставок налогов

И.В. Покровская, А.А. Дорофеев
(Москва)

Проблема анализа и выявления особенностей влияния психологического фактора на собираемость налогов в РФ к настоящему моменту практически не изучена, не говоря уже о построении каких-либо моделей с учетом психологических и поведенческих аспектов. А их роль, в особенности в переходные периоды развития экономики, динамичного изменения налогового законодательства, весьма существенна. В работе предложена модель поведения субъекта налогообложения, рассмотренная на примере налога на прибыль. В качестве независимой переменной x , влияние которой на характеристики налоговых поступлений будет изучаться, выберем ставку налога. В качестве такой характеристики, то есть функции от независимой переменной $f(x)$, выберем долю от реальной (которая фактически может быть получена) прибыли, которая будет «показана» как полученная. Дается анализ поведения этой функции. Очевидно, что $f(0)=1, f(1)=0$, то есть: если налог не взимается ($x=0$), то нет смысла «прятать» хоть какую-то часть прибыли; и наоборот, если ставка 100% ($x=1$), то нет смысла вообще показывать прибыль.

Вид функции $f(x)$ качественно характеризуется тремя зонами: $(0, a)$ - медленного уменьшения значений функции при относительно высоких значениях самой функции; (a, b) – начала резкого уменьшения значений функции; (b, d) – максимального уменьшения значений функции и $(d, 1)$ – медленного уменьшения значений функции при относительно невысоких значениях самой функции. Точка $x=c$ соответствует точке перегиба функции (в ней вторая производная функции равна 0) и является важнейшей характеристикой самой функции. Обычно функции такого типа аппроксимируют однопараметрическим семейством функций вида $f(x, \alpha) = e^{-\alpha x^2}$. Необходимо еще соблюсти условия нормировки, то есть: $f(0)=1, f(1)=0$. В работе приведено семейство функций $f(x, \alpha)$, удовлетворяющее таким условиям. Теперь возникает задача идентификации функции сокрытия налога для конкретных налогоплательщиков. Если бы эти функции были известны (то есть значения параметра α), то можно было бы поставить следующую оптимизационную

задачу: **Необходимо определить ставку налога x_{opt} , обеспечивающую максимальное поступление данного налога.**

Обозначим через $F(x)$ суммарные налоговые поступления при налоговой ставке x , через B_i реальную (без сокрытия) налоговую базу i -го налогоплательщика, а через $f(x, \alpha_i)$, как и ранее, функцию сокрытия налога для i -го налогоплательщика. Тогда оптимизационная задача формально

$$\text{записывается в виде } F(x_{opt}) = \max_x F(x) = \max_x \sum_{i=1}^N B_i f(x, \alpha_i) \quad (2), \text{ где } N -$$

общее число налогоплательщиков. Очевидно, что невозможно оценить значения α_i для каждого налогоплательщика в отдельности. Но хорошо известно, что существует достаточно небольшое число стереотипов поведения при принятии решений подобного рода. Ясно, что каждый такой стереотип поведения зависит от большого числа факторов, многие из которых не поддаются измерению или оценке. Поэтому единственно возможным способом реальной оценки функции $f(x, \alpha_i)$ является получение соответствующих экспертных оценок. Предложена методология выбора оптимальной ставки налога (на примере налога на прибыль).

Вначале производится структуризация (классификация) налогоплательщиков с целью получения однородных групп (классов) налогоплательщиков по стереотипам поведения в области налогообложения. Такую структуризацию необходимо проводить по косвенным параметрам, характеризующим специфику социально-экономической деятельности исследуемых налогоплательщиков. На сегодняшний день возможны два стратегических направления учета такой специфики – отраслевой и региональный. В работе обосновано использование регионального направления. Таким образом, необходимо построить такую классификацию регионов РФ, в которой вариабельность изучаемых стереотипов внутри классов будет существенно меньше таковой во всей генеральной совокупности. Это позволит достаточно надежно и с приемлемой дисперсией оценивать функцию $f(x, \alpha)$ независимо для каждого класса. Для построения таких классификаций предлагается использовать методы классификационного анализа данных [1]. После того, как классификация построена, для каждого класса находятся 1-3, так называемых, типопредставителя или типовых региона. Это регионы, для которых соответствующие точки в пространстве признаков расположены ближе всего к центру класса. Для простоты изложения предполагается, что каждый класс представлен только одним типовым регионом. В каждом типовом регионе проводится экспертиза с целью получения экспертных оценок значения α_j , где j – индекс региона.

Для проведения такой экспертизы предлагается использовать методы многовариантной экспертизы, позволяющие получать надежные и статистически значимые экспертные оценки [2]. В сложных случаях предлагается использовать стратифицированный способ экспертного оценивания, когда для типового региона проводятся экспертные оценки отдельно по различным группам субъектов экономической деятельности. Такая стратификация может идти по формам собственности, отраслевому признаку, величине предприятия и т.д., или по всем сразу. Для формирования соответствующей выборки можно воспользоваться методами стратифицированной выборки [3], используемыми в статистических и социологических исследованиях. Итоговая оценка получается как средневзвешенная оценка с учетом «веса» каждого страта (каждой группы), то есть его доли в объеме собранного в этом регионе моделируемого налога.

А именно: $\alpha_j = \sum_{i=1}^{n_j} v_{ij} \alpha_{ij}$, $\sum_{i=1}^{n_j} v_{ij} = 1$ (3), где α_{ij} - оценка для i -ой группы

(страта) в j -ом регионе, v_{ij} - «вес» i -ой группы в j -ом регионе для моделируемого налога. В итоге, с использованием того или иного способа экспертного оценивания получают оценки α_j . Теперь оптимизационная

задача (2) принимает вид: $F(x_{\text{opt}}) = \max_x F(x) = \max_x \sum_{j=1}^r B_j f(x, \alpha_j)$ (4), где j -

индекс класса в классификации регионов, а B_j - реальная (без сокрытия) налоговая база моделируемого налога для регионов j -го класса в целом, она равна сумме аналогичных величин для регионов, попавших при

классификации в j -ый класс: $B_j = \sum_{i=1}^{n_j} B_{ji}$, где B_{ji} - реальная (без

сокрытия) налоговая база моделируемого налога для i -го региона j -го класса, n_j - число регионов в j -ом классе, а $B_{ji} = \frac{B_{ji}(\phi, t_0)}{f[x(t_0, \alpha_j)]}$, где

$B_{ji}(\phi, t_0)$ - фактическая налоговая база моделируемого налога для i -го региона j -го класса за последний календарный год. Теперь имеются все данные для решения оптимизационной задачи (4).

Литература

1. Бауман Е.В., Дорофеюк А.А. Классификационный анализ данных // В сб.: «Избранные труды Международной конференции по проблемам управления. Том 1». М.: СИНТЕГ, 1999, С. 62-67.
2. Дорофеюк А.А. Методы мультигрупповой многовариантной экспертизы в задачах анализа и совершенствования организационных систем // 406

- Труды Института проблем управления РАН, том X, М.: ИПУ РАН, 2000, С.12-18.
3. Браверман Э.М., Литваков Б.М., Мучник И.Б., Новиков С.Г. Метод стратифицированной выборки в организации сбора эмпирических данных // Автоматика и телемеханика, №10, 1975, С. 65-78.

Диагностика структурных изменений в датчиках информационно – измерительных систем

В.Н. Попов
(Серпухов)

Увеличивающийся во всем мире спрос на датчики физических величин ставит перед производителями этих датчиков трудноразрешимую проблему: делать датчики высокоточными, а значит дорогими, обеспечивая конструктивно – кинематические параметры датчиков близкими к заданным техническими условиями, или поступится точностью и делать их относительно дешевыми, добиваясь нужной точности другими путями. От достоверности и полноты математических моделей (ММ) датчиков зависит точность и надежность функционирования комплексированных и интегрированных информационно – измерительных систем (ИИС). Знание структуры и параметров ММ позволяет создавать высокоточные системы. Однако такое знание стоит очень дорого – на этапе теоретической проработки необходимо исследовать влияние на датчики всевозможных помех, которые будут действовать на них на этапе эксплуатации систем, учесть вызываемые ими в датчиках нежелательные эффекты, наконец, в процессе производства необходимо стремиться к тому, чтобы технологически конструкция датчика обеспечивала отстройку от влияния учтенных в процессе проектирования помех. В результате стоимость датчиков становится сравнимой со стоимостью систем, в которых они должны использоваться. Второй подход сулит выигрыш в расширении области применения датчиков в том случае, если есть возможность уточнять структуру и параметры ММ дешевых датчиков, как на этапе приемосдаточных испытаний, так и в процессе эксплуатации их в составе систем. Проблема оценки структурных изменений в датчиках на этапе функционирования систем, в которые они входят, относится к проблеме диагностики. Для этой проблемы характерно то, что возможные структуры и параметры математических моделей измерителей известны заранее, однако неизвестно, какие составляющие этих моделей будут возбуждаться в процессе нормального функционирования систем в конкретные моменты времени. При этом под изменением структуры понимается не резкое, скачкообразное появление новых членов ММ, а достижение существующими членами модели таких значений, что не учитывать их

нельзя. Оценить структуру математической модели датчика можно следующим образом. На первом - подготовительном, этапе строится полная математическая модель датчика в пространстве параметров с учетом нелинейностей, отражаемых в уравнениях динамики членами, содержащими произведения координат и их производных, произведения координат на внешние воздействия, произведения внешних воздействий. Эти нелинейности отвечают требованиям монотонности и дифференцируемости и могут быть представлены в виде полиномов различной степени. На втором этапе решаются следующие задачи:

- классификация ММ путем введения логических признаков, показывающих наличие или отсутствие в модели нелинейностей, и детерминированных признаков, показывающих какова степень полинома, описывающего конкретную нелинейность ММ;

- проецирование этих признаков на ММ, определенные в функциональном пространстве вход - выходных соотношений: логических признаков - через ортогональные планы экспериментов и режимы работы датчиков; детерминированных признаков – через оценку решения уравнений состояния и наблюдения, сопоставляемых с макромоделью в виде функционального ряда Вольтерра (ФРВ) конечной размерности; ФРВ также определены для выбранного плана и режима работы датчика;

- анализ влияния режимов работы датчика на структуру уравнений его математической модели;

- применение методов математического планирования экспериментов для разработки планов проведения активных экспериментов, обеспечивающих в сочетании с различными режимами работы датчиков декомпозицию ММ для определения признаков нелинейностей, а также начальных приближений значений параметров уравнений состояния.

На третьем этапе - этапе диагностики, проводится активный эксперимент при работе датчика в различных режимах и подрежимах, при различных планах эксперимента. В результате должны быть выявлены логические и соответствующие им значения детерминированных признаков нелинейностей в каждом плане эксперимента по значениям коэффициентов ФРВ высших порядков. Четвертый этап - этап принятия решения, позволяет уточнить структуру ММ датчика путем учета полиномов, аппроксимирующих нелинейные функции ММ по выбранным критериям качества. В такой постановке задача диагностики математических моделей датчиков аналогична задаче распознавания образов: необходимо выбрать объект из множества объектов, характеризующихся совокупностью различных признаков, меняющихся в процессе эксплуатации. При детерминированной постановке задачи такими признаками могут быть:

- логические признаки, принимающие обычно два значения истинности (да – нет; система линейная – система нелинейная);

- собственно детерминированные признаки, принимающие конкретные числовые значения; этими признаками являются значения степени нелинейности полиномов, описывающих элементы структуры датчиков.

В качестве технических средств распознавания указанных признаков выступают экспериментально идентифицируемые в процессе активного эксперимента функциональные модели датчика, позволяющие сопоставлять апостериорные данные (степень сложности макромоделей) с априорной информацией об объекте (множеством решений нелинейных дифференциальных уравнений, определенных на множестве объектов) и на основе сопоставления определять, к какому объекту из множества он относится.

Предлагаемый метод рассмотрен на примере маятниковых акселерометров, применяемых в различных отраслях науки и техники для измерения ускорений.

Литература

1. Попов В.Н., Колесников И.М., Жебрак Л.М. Применение функционального описания Вольтерра для контроля датчиков навигационных систем // Контроль. Диагностика. 1999. №11.С.3-7.
2. Попов В.Н., Зобков А.Л. Диагностика текущего состояния первичных измерителей информационно – измерительных систем // Контроль. Диагностика 2001. №11.С.40-44.
3. А.С.1338657. Устройство для контроля динамических объектов. В. И. Кривошук, В. Н. Попов // Открытия. Изобретения. 1986. №21.

Использование информационных технологий для решения проблем малого и среднего бизнеса: структурный подход

Н.В. Попова
(Москва)

В процессе деятельности, связанной с открытием производств, специализирующихся на выпуске продуктов питания, руководителям и специалистам различных уровней приходится систематически решать повторяющиеся задачи. К ним относятся, например: освоение технологии и измерение параметров технологических операций, подбор или разработка рецептуры, составление технической и нормативной документации, выбор технологического, упаковочного оборудования, снижение издержек, повышение рентабельности, увеличение прибыли.

Поэтому, прежде всего, возникает вопрос, где взять интересующую информацию, к какому источнику обратиться; какое количество информации может считаться достаточной. Критерием достаточности может считаться определенный уровень накопленной информации, позволяющий руководителю принять взвешенное правильное решение, и свести

возможные потери (время, недополученная прибыль, прямые убытки) к минимуму.

Структурный подход к информационному сервису, позволяет достичь оптимального критерия достаточности и максимально полно ответить на значительную часть вопросов, возникающих как при открытии пищевого производства, так и в процессе работы/расширения, доукомплектации предприятия. При решении многих вопросов такой подход поможет предпринимателям выбрать из существующих информационных способов решения наиболее адаптированный к данному производству (первоначальным затратам, планируемой мощности, ассортименту), и, самое главное, сэкономить время, жизненные силы и деньги.

Существуют различные способы решения задач, которые возникают перед предпринимателем, некоторые из которых освещены в докладе.

Прежде всего, это вопрос выбора направления деятельности предприятия (организация, модернизация, перепрофилирование) и поставщика оборудования.

В докладе приведена классификация оборудования по ценовому признаку. Проанализировано состояние вторичного рынка пищевого технологического, упаковочного, торгового, холодильного оборудования и выделены “группы риска” (восстановленное, консервационное и др.).

Предприниматель, который принял решение начать производство пищевых продуктов, в первую очередь, сталкивается с проблемой подготовки нормативной документации и получения санитарно-гигиенического заключения СЭС. Нами предложена схема подготовки нормативно-технической документации и разработки рецептуры, позволяющая в короткие сроки решать эти вопросы. Нужно отметить, что данная схема приемлема для небольших и средних производителей, т.к. крупные предприятия имеют в штате одного или нескольких технологов, которые отвечают за разработку технических условий на продукцию.

Еще одна проблема - сертификация продукции - процедура подтверждения соответствия, посредством которой независимая от изготовителя (продавца, исполнителя) и потребителя (покупателя) организация удостоверяет в письменной форме, что продукция соответствует установленным требованиям.

Производители пищевых продуктов, которые не подлежат обязательной сертификации, проводят добровольную сертификацию в целях подтверждения соответствия продуктов требованиям стандартов, технических условий, рецептур и других документов.

В последнее время потребители получают много информации, касающейся качества продукции отечественных и иностранных производителей, поэтому производители стараются “подстраховаться”: покупатель предпочтет сертифицированный продукт продукту, не

прошедшему контроль государственных органов. Нами разработана схема проведения сертификации пищевой продукции.

Предложенная нами многоуровневая структура информационной и технологической поддержки представителей малого и среднего бизнеса позволяет решить вопросы выбора поставщика оборудования, подготовки нормативно-технической документации, сертификации продукции, обучения персонала и ряд других. Она включает в себя следующие этапы: постановку задачи; определение номенклатуры выпускаемой продукции и планируемой производительности; выбор поставщика оборудования; подготовку коммерческого предложения; разработку эскизного проекта; подготовку документов для сертификации; подбор специализированной литературы; комплектацию технологической линии или отдельных единиц оборудования; поставку и шеф-монтаж оборудования, гарантийное и послегарантийное обслуживание, технологическую поддержку.

Безусловно, в том случае, когда производитель собирается приобрести одну единицу оборудования, нет необходимости использовать структурный подход. Но это случается крайне редко. В том случае, когда предприниматель планирует полностью оснастить цех, предприятие, производственную линию, тогда технологическая и информационная поддержка необходима, а использование предложенной нами схемы приведет к экономии финансовых средств, времени и жизненных сил. Решение постоянно возникающих проблем самостоятельно или, пользуясь услугами различных фирм, может привести к серьезным просчетам в бизнесе.

Литература

1. Попова Н.В. Использование информационных сервисных систем для решения проблем малого и среднего бизнеса//Торговое оборудование в России. Москва, 2003.
2. Попова Н.В. Как открыть предприятие по производству продуктов питания. Механизм принятия решений//Эксперт. Оборудование. Москва, 2002.
3. Попова Н.В. Осознанная необходимость – сертификация пищевой продукции//Экономика сельскохозяйственных и перерабатывающих предприятий. Москва, 2002.

Восстановление траекторий движения пера по изображениям рукописных символов

Р.В. Поцпаев, И.Б. Петров

(Москва)

Введение

Среди существующих подходов к «оффлайн» задаче распознавания рукописных символов важное место занимает метод, основанный на частичном восстановлении траектории движения пера по изображению символа. Такой подход позволяет интегрировать методы решения «онлайн» и «оффлайн» задач распознавания рукописных символов.

В последние годы появилось большое количество публикаций посвященных восстановлению информации о движении пера и интеграции «онлайн» и «оффлайн» задач [1-3].

В работе предлагается новый метод восстановления траектории движения пера, основанный на статистическом подходе к распознаванию образов. Результатом обработки каждого изображения символа является не единственная траектория, а список гипотез возможных траекторий и вероятностей их возникновения.

Восстановление штрихов в узлах и случайных разрывах

Наш подход базируется на методе предобработки [4], который состоит в следующем: изображение разбивается на полосы черных точек, соответствующие непересекающимся отрезкам штрихов (регулярные области) и областям пересечения штрихов (узловые области).

Каждую траекторию пера можно представить в виде последовательности средних линий регулярных областей соединенных в узлах и случайных разрывах. Траектория может дважды проходить вдоль одной регулярной области, в этом случае, регулярная область расщепляется на два отрезка траектории (см. рис. 1, регулярные области, отмеченные номерами).

Пронумеруем концы регулярных областей, входящих в узел числами от 1 до m . Решение задачи восстановления штрихов в узле или конфигурацию узла можно представить в виде симметричной бинарной матрицы C_m , причем $c_{ij} = 1$ если концы областей с номерами i, j образуют штрих. Для нахождения верной конфигурации воспользуемся байесовским решающим правилом:

$$C^* = \arg \max_{C \in T_m} p(C | X) = \arg \max_{C \in T_m} \frac{p(X | C)p(C)}{\sum_{C \in T_m} p(X | C)p(C)},$$

где $p(X | C)$ – функция правдоподобия для конфигурации C , $p(C)$ – априорная вероятность возникновения C .

Возможную траекторию внутри узла, соединяющую средние линии областей i, j представим в виде полинома третьей степени $P_3(t)$, для которого выполнены граничные условия в точках соединения (см. рис. 1).

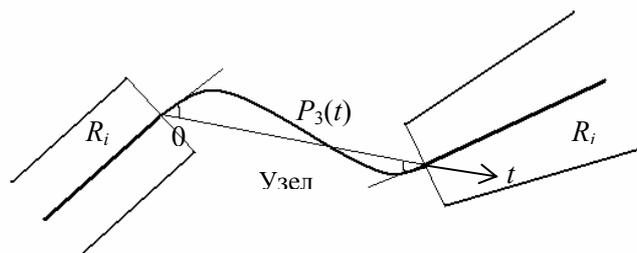


Рис. 1. Восстановление траектории в узле

Информацию об узле представим в виде симметричной матрицы $X = \|x_{ij}\|_{m \times m}$, где $x_{ij} = \frac{1}{L} \int_0^L (\ddot{P}_3(t))^2 dt$.

Будем считать, что x_{ij} зависит только от c_{ij} , следовательно

$$p(X | C) = \prod_{i=1}^m \prod_{j=i+1}^m p(x_{ij} | c_{ij}).$$

На большой выборке узлов делается статистическая оценка распределений $p(x | c = 0)$, $p(x | c = 1)$ с помощью метода гистограмм и метода « k ближайших соседей», а также вероятностей $p(C)$ для различных типов конфигураций.

Для восстановления случайных разрывов также применяется байесовское решающее правило.

Определение вероятностей конфигураций всех узлов и разрывов на изображении позволило вычислить вероятности всевозможных траекторий движения пера и отобрать список наиболее вероятных траекторий. На рисунке 2 показаны примеры восстановления траекторий написания.

Экспериментальные результаты

Для исследований использовалась база, состоящая из 5200 изображений рукописных символов полученных из самых различных источников – 200 изображений каждой буквы английского алфавита.

В таблице 1 приведены результаты обработки изображений базы.

Таблица 1. Распознавание конфигураций узлов и восстановление траекторий

Длина списка кандидатов	1	3	5	10	15
Доля правильно распознанных конфигураций узлов, %	87.3	98.3	99.6	100	100
Доля правильно восстановленных траекторий, %	74.1	85.1	92.2	98.1	99.2

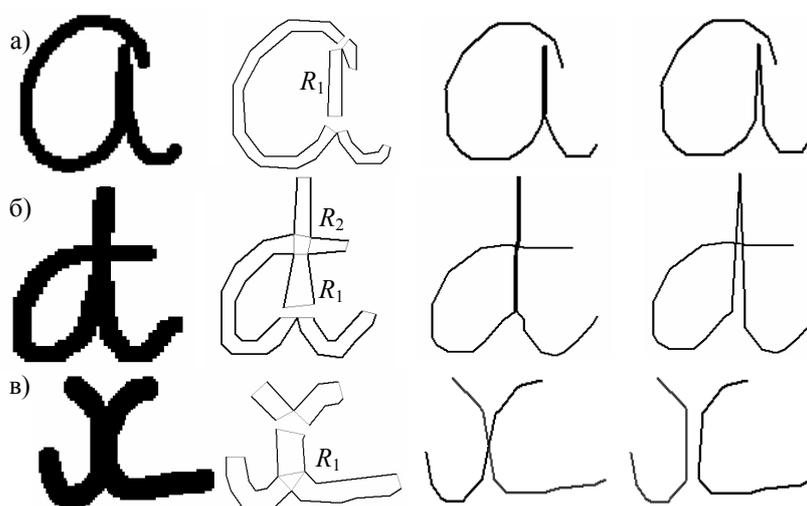


Рис. 2. Восстановление траектории по изображению

Литература

1. Doermann D. S., Rosenfeld A. The interpretation and reconstruction of inferring strokes // International Workshop on Frontiers in Handwriting Recognition — 1993. — P. 29–40.
2. Nishida H. An approach to integration of off-line and on-line recognition of handwriting // Pattern Recognition Letters — 1995. — V. 16. — P. 1213–1219.
3. L'Homer E. Extraction of strokes in handwritten characters // Pattern Recognition — 2000. — V. 33. — N 10. — P. 1147–1160.
4. Поцпаев Р.В., Петров И.Б. Эффективный алгоритм предобработки изображений для структурных методов распознавания рукописных символов // Электронный журнал "Исследовано в России", 19,

Морфологический анализ изображений: сравнение по форме, узнавание, классификация, оценка параметров

Ю.П. Пытьев, А.И. Чуличков

(Москва)

Введение

Хорошо известно, что изображения одной и той же сцены, отвечающие различным условиям освещения и(или) измененным оптическим свойствам объектов, могут различаться радикально. Это обстоятельство порождает значительные трудности в прикладных задачах анализа и интерпретации изображений реальных сцен, в которых решение не должно зависеть от условий регистрации изображений. Речь идет, например, о задачах выделения неизвестного объекта на фоне известной местности, узнавания известного объекта на произвольном фоне, классификации объектов по их изображениям, полученным при неконтролируемых условиях регистрации, о задаче совмещения изображений одной и той же сцены, полученных в различных спектральных диапазонах и т.д. Для решения перечисленных задач были разработаны методы морфологического анализа изображений, оказавшиеся достаточно эффективными.

Основная идея морфологического подхода состоит в математическом исследовании модели формирования изображений с целью поиска симметрий, выражающихся в инвариантности задачи к тем или иным преобразованиям зарегистрированного изображения и параметров модели измерения, моделирующих изменения условий наблюдения, и выделении максимальных инвариантов таких преобразований. Эти инварианты носят название формы изображения или сигнала; дальнейший анализ осуществляется в терминах форм.

Центральное понятие морфологического анализа – форма изображения – тесно связана с моделью регистрации изображения объекта или сцены. Например, пусть изображение получено от объекта, поверхность которого состоит из участков оптически однородных плоскостей, освещаемых однородным световым потоком. Тогда каждый участок такой плоскости на изображении объекта будет иметь однородную яркость; его изображение можно рассматривать как кусочно постоянную функцию $f(\cdot)$, заданную на поле зрения X , являющегося ограниченным подмножеством плоскости R_2 , принимающую одно и то же значение c_i на подмножествах $A_i, i=1, \dots, N$. Эти подмножества попарно не пересекаются и в сумме составляют все поле зрения X . Все множество изображений зададим как множество квадратично интегрируемых на X функций $L_2(X)$, значение функции $f(\cdot)$ в точке x поля зрения X назовем яркостью изображения $f(x)$. Если под изменением условий

регистрации понимать вариации светового потока излучения, освещающего сцену, то эти изменения сказываются на значениях яркости c_1, \dots, c_N , но разбиение X на области A_1, \dots, A_N остается неизменным. Это означает, что преобразования, позволяющие узнавать объект при любых разрешенных условиях, состоят во всевозможных преобразованиях яркости участков A_1, \dots, A_N поля зрения X . Максимальным инвариантом таких преобразований является проектор в $L_2(X)$ на N -мерное подпространство кусочно постоянных функций с областями постоянной яркости A_1, \dots, A_N . Этот проектор и назовем формой изображения объекта.

В морфологическом анализе цветных изображений в качестве модели изображения используется векторнозначная функция, заданная на поле зрения; ее значение в каждой точке поля зрения определяются спектральными характеристиками объекта и спектральным составом освещения. Форма цветного изображения определяется в зависимости от решаемой задачи как инвариант преобразований яркости, цвета или яркости и цвета исходного изображения.

Сравнение изображений по форме

Заметим, что в рамках описанной выше модели изменение изображения объекта вследствие изменений условия наблюдения можно описать преобразованием $F(\cdot)$, действующим на яркость предъявленного изображения $f(\cdot)$: $g(x) = F(f(x))$, $x \in X$. Здесь $g(\cdot)$ – изображение объекта, полученное из изображения $f(\cdot)$ вследствие изменения условий наблюдения. Действительно, в результате таких преобразований все точки поля зрения изображения $f(\cdot)$, имеющие одну и ту же яркость c , на изображении g также будут иметь одинаковую яркость $F(c)$, возможно, отличную от c . Однако может случиться так, что две или более области различной яркости изображения $f(\cdot)$ на изображении $g(\cdot)$ будут иметь одну и ту же яркость. В этом случае множества постоянной яркости A_i и A_j , имевшие различную яркость на изображении $f(\cdot)$, окажутся "склеенными" на изображении $g(\cdot)$. Так как геометрическая форма областей одинаковой яркости изображений при "склеивании" множеств упрощается, можно считать, что изображение $g(\cdot)$ по форме не сложнее, чем $f(\cdot)$.

Узнавание объекта по его изображению и выделение отличий по форме

Пусть дано изображение f некоторого объекта и построена его форма в виде проектора P_f . Задача узнавания объекта по предъявленному изображению g в терминах его формы сводится к проверке равенства $P_f g = g$: если оно выполнено, то можно подобрать условия регистрации, при которых объект породит изображение g , если же нет, то в рамках принятой модели нет никаких оснований узнать в изображении g заданный объект. В этом случае можно определить, чем отличаются по форме изображения f и g : это дается изображением "невязки" $q = g - P_f g$.

Величина невязки дает представление о похожести формы

предъявленного изображения g на форму изображения f .

Методы выделения отличий в сценах по их изображениям используются для визуализации дефектов изделий в микроэлектронике, в охранных системах и в других приложениях.

Кроме того, на практике предъявляемые изображения искажены шумом, поэтому равенство $g - P_f g = 0$ не достигается даже на изображении, полученном от той же сцены, что и f . В случае, когда изображение g искажено шумом неизвестной дисперсии, задача узнавания формально сводится к выбору между двумя решениями: предъявленное изображение есть искаженное шумом изображение заданной формы, или искаженное шумом изображение константы. Действительно, т.к. шум произволен, то любое изображение, отличное по форме от f , можно рассматривать как искаженное шумом изображение константы). Задача выбора между этими двумя гипотезами инвариантна к преобразованиям с максимальным инвариантом

$$t_f(g) = \frac{\|(I - P_f)g\|^2}{\|(P_f - E)g\|^2}, \quad (1)$$

где I – единичный оператор, а E – проектор на множество изображений $\{g = const\}$. Чем меньше его значение, тем больше изображение g по форме похоже на изображение f и не похоже на константу.

Морфологические методы узнавания объектов по их изображениям используются при решении задач обнаружения трещин в стенках буровых скважин, поиска реперных меток на пластинах в микроэлектронике, узнавания фрагмента местности по карте.

Морфологическое оценивание параметров объекта по его изображению

Часто на практике оказываются неизвестными параметры объекта, определяющие, например, его расположение, размеры и т.п. В этом случае используется параметрическое множество форм изображения объекта, или проекторов $P_f(\lambda)$. Оценка значения параметра λ , определяющего свойства объекта по его изображению g , производится минимизацией функционала $t_f(g, \lambda)$ или выбором параметра λ из множества его допустимых значений.

Морфологические методы оценивания параметра объекта по его изображению используются при определении параметров дефектов буровых скважин, определения координат маркерных знаков на кремниевых пластинах в микроэлектронике, в навигационных задачах.

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований, проект № 02-01-00579.

Об одном методе распознавания символов на карте

С.С. Раджабов

(Ташкент)

Одной из задач распознавания визуальной картографической информации является задача распознавания символов на карте (название местностей, рек, озёр и т.п.) различной ориентации и размера. В данной работе применен структурный подход к решению этой задачи.

Пусть $S = \{s_{ij}\}$ – скелетное бинарное изображение символа, полученное в результате применения алгоритмов предварительной обработки и скелетизации, описанных в [1].

Определение 1. Маской размера $m \times n$ точки (i, j) называется множество

$$M_{m \times n}(i, j) = \{(k, l) \mid |i - k| \leq R_1, \quad |j - l| \leq R_2\}$$

, где $m = 2R_1 + 1, \quad 2R_2 + 1$.

Определение 2. Окрестностью размера $m \times n$ точки (i, j) называется множество

$$O_{m \times n}(i, j) = M_{m \times n}(i, j) \setminus (i, j)$$

Определение 3. Граничной окрестностью размера $m \times n$ точки (i, j) называется множество

$$\bar{O}_{m \times n}(i, j) = \{(k, l) \mid |i - k| = R_1, \quad |j - l| = R_2\}$$

, где $m = 2R_1 + 1, \quad 2R_2 + 1$.

Операцию подсчёта количества связанных точек в некоторой окрестности $O_{m \times n}(i, j)$ точки s_{ij} обозначим как $C[O_{m \times n}(i, j)]$.

Определение 4. Точка $s_{ij} \in S$ называется изолированной, если

$$C[O_{m \times n}(i, j)] = 0$$

Определение 5. Точка $s_{ij} \in S$ называется концевой, если

$$C[O_{m \times n}(i, j)] = 1$$

Определение 6. Точка $s_{ij} \in S$ называется узловой точкой I рода, если

$$C[O_{m \times n}(i, j)] = 3$$

Определение 7. Точка $s_{ij} \in S$ называется узловой точкой II рода, если

$$C[O_{m \times n}(i, j)] > 3$$

Формальный язык описания изображения

Для описания изображения символа воспользуемся следующими обозначениями: изолированная точка – 0; концевая точка – 1; точка перегиба – 2; изогнутый участок линии скелета – 3; узловая точка I рода – 4; узловая точка II рода – 5.

Применяя данные обозначения, получим векторы, описывающие изображения символов. Отсортировав (она производится для увеличения быстродействия алгоритма) все векторы, получим эталон алфавита.

Алгоритмы выделения признаков

Алгоритмы нахождения узловых точек I, II рода, изолированной и концевой точек очевидны: достаточно применить оператор $C[O_{3 \times 3}(i, j)]$

для всех $S_{ij} \in S$.

Участок между точками $S_{tp} \in S$ и $S_{mn} \in S$ (точки перегиба, узловых точек I, II рода, концевые точки) является изогнутым, если на всём пути [2]

$$\rho(s_{ij}, s_{kl}) > \rho(s_{ij}, s_{il})$$

где $\rho(s_{ij}, s_{kl})$ - расстояние между точками S_{ij} и S_{kl} , $|i - k| \leq 3$, $|j - l| \leq 3$.

Данный метод позволяет распознать символы независимо от ориентации и размера символа.

Литература

1. Садыков С.С., Кан В., Самандаров И. Методы выделения структурных признаков изображений // Ташкент, 1990. С. 72-99.
2. Садыков С.С. Цифровая обработка изображений // Ташкент, 1990. С. 212-215.

Ориентирующие базы данных для совершенствования решения технологических задач

В.Е. Романов

(Санкт-Петербург)

Системный характер проблемы

Общая цель и содержание освещаемых в докладе исследований состоят в создании четко структурированной системы теоретических положений и соответствующих им баз знаний, адаптированных к методам определения зависимостей выходных свойств производимых нитей от систем параметров

технологических процессов их формирования. Конечным итогом этих исследований должно быть создание автоматизированной информационной системы для проектирования и эксплуатации соответствующего оборудования. Условием эффективного достижения этой цели является придание исследованиям системного характера, обеспечивающего четкое выделение составных элементов системы, а также возможность ее структурного и содержательного развития. При этом должно быть обеспечено включение в разрабатываемую систему множества ранее разработанных, но имеющих разобщенный характер методов и результатов. Структура системы определяется как соответствующей ей материально-производственной базой (основное и вспомогательное оборудование, используемые сырьевые материалы), так и информационной составляющей, определяемой структурами баз знаний, способами накопления, хранения и использования знаний.

Основные теоретические методы

В соответствии со спецификой проблемы основой исследования служат современные методы теории трудно формализуемых задач: теория распознавания образов (ТРО), теория нечетких множеств, теория поисков закономерностей [1], [2]. На этой базе разрабатывается эвристическая схема изучения технологических процессов производства нитей, адаптированная к задачам прогнозирования, совершенствования и классификации потребительских свойств нитей; формулируются требования к характеристикам используемых баз данных и разрабатываются методы получения и совершенствования соответствующей информации. Агрегативные подходы к построению системы обеспечивают возможность автономных исследований отдельных ее компонентов.

Основное внимание уделено вопросам получения процедурных знаний, используемых для анализа и переработки баз пассивных (декларативных) знаний, содержащих информацию о параметрах технологических процессов и о физических характеристиках оборудования, сырья. Рассматриваются возможности использования таких структур знаний и данных, как фреймы, отражающие внутренние свойства объектов; семантические сети, отражающие внешние связи объектов; вычислительные модели, сценарии. Используются методы погружения знаний в пространства с семантическими метриками, методы количественных и порядковых оценок информации на основе различного типа шкал. Рассматриваются общие перспективы дальнейшего развития методов теоретического и экспериментального исследования объектов, для которых невозможно построить математические модели, отражающие их внутренние свойства и их реакции на внешние воздействия.

Применение теории распознавания образов к задачам классификации технологических схем производства нитей

При создании ориентирующих баз данных (знаний) предполагается максимальное использование имеющейся, экспериментально полученной информации о реализации различных процессов производства нитей на существующих предприятиях. Эти процессы рассматриваются в качестве прецедентных экземпляров, а соответствующая им информация используется для указания их места в признаковом пространстве. Классификация процессов на основе теории распознавания образов исходит из требования, чтобы процессы, мало различающиеся по своим физико-химическим параметрам, были близки как элементы соответствующего признакового пространства. Это требование налагает сравнительно незначительные ограничения на выбор метрики пространства. Более сложные ограничения возникают из требования, чтобы близость процессов по всем параметрам обеспечивалась их близостью по одним только входным параметрам, т.е. по параметрам, задаваемым оператором, реализующим процесс производства. Другие (выходные) параметры определяются внутренними характеристиками перерабатываемого сырья и используемых материалов и оборудования.

Поскольку указанные внутренние характеристики используемых объектов и их взаимосвязи остаются неизвестными, постольку отсутствует возможность построить формальные математические модели процессов, и возникает необходимость их изучения неклассическими средствами. Первым шагом в этом направлении является их классификация на основе имеющихся прецедентов. Следующие этапы изучения состоят в построении аналитических представлений связей входных и выходных параметров и в проверке точности этих представлений. При наличии значительных расхождений результатов с экспериментальными данными метод построения аналитических представлений повторяется с учетом дополнительной информации, повышающей его точность и получаемой соответствующими экспериментальными средствами или на основе уточненного теоретического анализа отдельных моментов процессов.

Прогнозирование потребительских свойств нитей

Принимаемое за основу деление технологических процессов на классы приобретает значительную эвристическую ценность вследствие дополнения алгоритмами уточненной оценки зависимости потребительских свойств нитей от параметров их формирования (от входных параметров). Вследствие значительного количества параметров, характеризующих и определяющих различные стадии процессов получения нитей, не является очевидной возможность выявления закономерностей, устойчиво связывающих потребительские характеристики нитей со сравнительно небольшим числом каких-либо входных параметров, выбираемых в качестве основных. Однако

(по крайней мере при строгом соблюдении задаваемых режимов производства) такие устойчивые связи существуют и могут быть выражены методами теории антонимов и на основе использования методов линейных направлений и согласующих функций (методы ЛН-СФ). В настоящее время эти методы являются наиболее перспективными; в отличие от статистических методов они не требуют получения обширной экспериментальной информации.

Техника использования методов теории антонимов вполне сформирована и установилась. В основе методов линейных направлений и согласующих функций лежит построение функций, которые точно отражают потребительские свойства нитей для тех технологий, которые были изучены экспериментально (для прецедентных технологий). Для других технологий эти функции дают прогностические оценки потребительских свойств на основе согласующих аппроксимаций. Возможность значительного развития методов ЛН-СФ обусловлена, прежде всего, тем, что базисы для формирования согласующих функций могут выбираться различным образом и изменяться, по мере уточнения знаний о поведении нити, о свойствах ее внутренней структуры на различных стадиях ее переработки. Программное обеспечение методов апробировано на конкретных задачах различного прикладного характера.

Проведенные исследования показывают, что развитие языков программирования, работающих со сложно структурированными данными, успехи в развитии общей теории систем и теории баз знаний, успехи в развитии теории распознавания образов и нечетких логик создали надежную основу для построения интеллектуальной системы проектирования и обслуживания производств химических нитей. В настоящей работе намечена общая архитектура этой системы и указаны основные методы ее развития.

Литература

1. Романов В.Е., Климов В.А., Саакян Р.Р. К развитию информационных технологий в области технологии химических волокон // Вестник Санкт-Петербургского государственного университета технологии и дизайна. СПб.: СПбГУТД, 2001. - № 5. С. 95-109.
2. Цаленко М.Ш. Семантические и математические модели баз данных // Итоги науки и техники. Информатика. М.: ВИНТИ, 1985. - Т. 9. 207 с.

Применение методов теории распознавания образов для прогнозирования свойств легированных сплавов и сталей

В.Е. Романов, Л.Т. Жукова, Р.Р. Саакян

(Санкт-Петербург, Благовещенск)

Типичная область применения легированных сталей – аэрокосмические и автомобильные детали, крупные турбины, скальпели и ножи, режущие инструменты и другие изделия, от которых требуется высокая прочность, а также химико-технологическая аппаратура, оборудование пищевой промышленности и всевозможные декоративные металлические изделия.

Для текстильной и легкой промышленности особый интерес представляет задача формирования и прогнозирования свойств и характеристик легированных инструментальных сталей для производства материалов, инструментов и деталей машин текстильной и легкой промышленности, а также машинных швейных и трикотажных игл, с целью обеспечения для них требуемых уровней показателей качества [1, 2].

Рассматриваемая задача с точки зрения регулярных подходов к ее решению и существующей практики может быть отнесена к категории трудноформализуемых.

Одна из отличительных особенностей данных трудноформализуемых задач заключается в наличии большого набора переменных, определяющих свойства объектов.

С другой стороны, вследствие компьютеризации исследования, хранения и накопления различных сведений и разработки на этой основе методов принятия решений в современных условиях возникает возможность решения указанной выше задачи на основе применения информационных технологий (ИТ). При реализации ИТ целесообразно опираться, в первую очередь, на базовые принципы и приемы теории распознавания образов [3], а также на примыкающие к ним научные направления и подходы [4].

Наличие этих причин, а также постоянное обновление и интенсификация существующих и возникновение новых технологических процессов обуславливает необходимость разработки методологического обеспечения системы распознавания, прогнозирования свойств и характеристик готовой продукции, и их классификации.

Нужно отметить, что при решении задач прогноза и классификации для технологических объектов, имеют место определенные сложности, связанные со спецификой конкретной технологии. Это связано с тем, что при непрерывных параметрах априорно не существует четкого разделения классов, и, следовательно, имеет место сложность определения классов обычными методами распознавания. С другой стороны, в большинстве случаев классы имеют достаточно сложные формы и являются линейно-несепарабельными.

В работе предлагается система информационного методологического

обеспечения распознавания, прогнозирования свойств и характеристик легированных сплавов и сталей, а также их классификации с применением методов теории распознавания образов. Здесь можно выделить ряд позиций, отличающихся своей направленностью:

1. Обобщение накопленных к настоящему времени сведений в теории и практике производства и эксплуатации легированных сплавов и сталей.
2. Позиции, отражающие новые постановки для отрасли легированных сплавов и сталей.
3. Позиции, являющиеся развитием существующих информационно-математических подходов к целям создания рассматриваемого методологического обеспечения. При этом развитие осуществлялось с учетом существующих подходов в экспериментально-теоретическом моделировании и обработке информации.

В работе проводится разработка некоторых позиций в области методологии системы распознавания и прогнозирования свойств и характеристик легированных сплавов и сталей, а также их классификации в зависимости от параметров формования и эксплуатации на базе подходов теории распознавания образов, извлечения закономерностей из баз данных и теории нечетких множеств.

Предложенную систему можно использовать для решения следующих конкретных задач:

- создание предпосылок для систем оперативного контроля качества и управления процессов производства легированных сплавов и сталей;
- разработка системы информационной поддержки планирования экспериментов при проектировании новых технологий на основе уже имеющейся информации в этой области;
- прогнозирование поведения легированных сплавов и сталей в условиях переработки и эксплуатации;
- создание методологической базы для проведения классификации существующих легированных сплавов и сталей в пространстве их качественных характеристик, для обнаружения закономерностей между существующими классами и прогнозирования местоположения новых легированных сплавов и сталей в этой системе классификации.

Последняя задача является главной задачей разработанной системы и дает возможность в пространстве параметров формования регулировать и направлять исследования, предназначенные для получения новых легированных сплавов и сталей, соответствующих новым требованиям эксплуатации.

Литература

1. Жукова Л.Т. Теоретические исследования тепловых процессов в иглах

- швейных машин .-Известия вузов. Приборостроение, 1998, № 6,с.74-78.
2. Жукова Л.Т. Криогенная обработка материалов, инструмента и деталей машин текстильной и легкой промышленности //Учебное пособие//СПб.:СПГУТД, 1998, 35с.
 3. Журавлев Ю.И. “Распознавание образов”, в книге “Избранные научные труды”, издательство “Магистр”, М., 1998.
 4. Жукова Л.Т., Климов В.А., Саакян Р.Р. Об информационных технологиях в формировании свойств и характеристик легированных сталей и сплавов // Математические методы распознавания образов (ММРО-10). Докл. X Всеросс. конф. – М.: РАН, Вычислительный центр, 2001. - С. 215-217.

**Применение методов распознавания образов для
прогнозирования свойств и характеристик объектов
обработки в двухфазных многокомпонентных
диффузионных средах**

В.Е. Романов, И.В. Фоменко, А.П. Жабко, А.М. Киселев

(Санкт-Петербург)

Примером рассматриваемых в докладе объектов являются технологические системы красильно-отделочных производств (КОП). В этих системах твердую фазу представляет собой окрашиваемый субстрат, а жидкую - красильный раствор, в общем случае смесовой.

В процессе обработки происходит диффузионный перенос красителя из жидкой фазы в твердую, следствием чего является окрашивание субстрата. Часто решаемыми задачами в КОП при этом являются подбор состава и концентраций красителей для получения некоторого заданного цвета или прогнозирование цвета, который получится в результате обработки субстрата при некоторых заданных параметрах технологического процесса.

Цвет продукта в КОП принято оценивать с помощью спектральной функции коэффициента отражения $R(\lambda)$, где λ - длина волны света. Для видимого диапазона λ принимает значения от 400 до 700 нм.

На процесс окраса влияют многие параметры: температура, время, но, прежде всего, концентрация красителя C . Чем больше концентрация, тем меньше коэффициент отражения. Зависимость почти линейна.

$$\Delta \frac{1}{R} = a \cdot \Delta C$$

Здесь a - коэффициент пропорциональности. Он разный для разных длин волн. Данное соотношение используется в приближенных расчетах.

К сожалению указанная линейность наблюдается лишь при небольших концентрациях - до 0.5%. В связи с этим на практике чаще используется

соотношение Гуревича-Кубелки-Мунка [1].

$$\Delta \frac{(1-R)^2}{2R} = a \cdot \Delta C$$

Для данного соотношения линейность сохраняется в некоторых случаях для величин C до 2%.

Многолетняя работа по совершенствованию формул для расчета концентраций привела к появлению многочисленных нелинейных математических моделей, используемых для разных красителей и тканей. Многие из них содержат поправки и коэффициенты, позволяющих учесть чистоту красителей, поверхностные свойства тканей, взаимодействие красителей между собой. Ограничения на область применения, сложность и специфичность указанных моделей не позволяют их широко использовать на практике. Поэтому для работы с большими концентрациями представляется разумным построение полномасштабной многомерной интерполяционно-аппроксимационной экспериментально-теоретической модели, использующей для представления аналитических зависимостей (АПЗ), например, аппарат линейных направлений и согласующих функций (ЛН-СФ) [2] или ортогональные полиномы [3].

Построение такой модели связано с большими затратами. Для сокращения ее размера приходится ограничить набор используемых красителей. Однако, в последствии, ее использование позволяет автоматически решать проблемы с нелинейностями и учетом взаимодействия красителей.

К сожалению, рассчитывать на стабильность номенклатуры используемых красителей и материалов не приходится. Нестабильность внешних экономических связей, неустойчивость отечественных производителей, конкуренция, которая приводит к смене производителей, все названное приводит к периодической смене используемых красителей. При этом естественно желание подобрать новый краситель похожий на используемые ранее. Определить сходство можно по априорным данным (составу, названию, производителю) либо по анализу модели его действия.

Построение модели действия красителя ведут путем подбора похожих классических, соответствующих известным (используемым ранее) красителям. Для облегчения данного процесса модель рассматривают в виде совокупности подмоделей, действующих на каждом из диапазонов длин волн света. В качестве таких диапазонов в КОП обычно рассматривают шестнадцать участков по 20нм на оси λ . На каждом таком участке некоторые красители оказывают сильное окрашивающее действие, другие - слабое. Кроме этого на действие красителя оказывает влияние степень диффузионной активности. Чем она больше, тем больше данного красителя попадает в субстрат, затрудняя действие других красителей. В этом, в

частности, проявляется взаимодействие красителей между собой.

Оценивая учитываемые параметры красителей с помощью нечетких относительных величин можно построить соответствие между сочетанием параметров используемых красителей и некоторым классом модели их действия. Конкретные сочетания красителей, в данном случае, и проявление их окрашивающего действия в некотором диапазоне длин волн λ будут являться прецедентами для построения различных классов таких моделей. В дальнейшем для построения модели действия нового красителя достаточно будет провести его классификацию по относительно небольшому количеству выкрасок и, возможно, выполнить некоторую коррекцию найденной модели в рамках данного класса. Априорные сведения о красителе позволяют сократить количество выкрасок. Возможна и обратная задача - определение параметров красителя (состава и свойств) по результатам распознавания и классификации модели его действия.

К сожалению, использование описанной модели вряд ли позволит полностью отказаться от уточняющих выкрасок, особенно при высоких требованиях к точности. Это обусловлено, в частности, тем, что свойства красителей могут несколько меняться даже в рамках одной партии. Однако такая модель может позволить оптимизировать план экспериментов, уменьшить их число и повысить точность окончательного результата.

Литература

1. Ершов А.П., Хархаров А.А. Цвет и его применение в текстильной промышленности -Л.:Издат-во Ленинградского ун-та, 1974. - 164 с.
2. Саакян Р.Р. Решение трудноформализуемых задач с регуляризацией обработки экспериментальных данных // Вестник Санкт-Петербургского университета технологии и дизайна №6 2002. - 7 с.
3. Акопджанян Г.М., Червяков В.В. Алгоритмическое обеспечение автоматизированной системы первоначального подбора рецептур крашения трикотажного полотна прямыми красителями. // Межвуз.сб.науч.тр. /СПГУТД, -СПб.: 1994.

Компьютерное обучение как трудно формализуемая задача

В.Е.Романов, И.В.Фоменко, И.А.Мелентьева

(Санкт-Петербург)

Компьютерное обучение (КО) - составная часть системы образования (СО). Поддержка системы образования с различных позиций считается важной государственной задачей.

Наука и техника в последнее время развиваются ускоренными темпами. Это обуславливает и постоянный рост требований к СО. Несмотря на постоянное реформирование СО не вполне с ними справляется. Это связано, в частности, с тем, что психическая нагрузка на обучаемых и обучающихся

растет. Другим осложняющим фактором является ограничения государственного финансирования и необходимость, в связи с этим, снижения стоимости обучения.

Все сказанное диктует необходимость изменения технологии обучения, основанной на широком использовании самих научных достижений. Особенно это касается достижений в компьютерной индустрии и в области информационных технологий.

Потенциал использования КО в СО представляется очень большим. Причем до такой степени, что это требует осторожности.

В данной работе предполагается ориентацию в качестве центральной на технологию искусственного интеллекта (ИИ), т.е. технологию имитации деятельности человека (преподавателя) с помощью компьютера, и, в частности, на методы распознавания образов (РО), которые в числе других подходов предполагают принципы деления объектов (обучаемых и обучающие программы) на классы и принципы прецедентности [1].

Практической основой принципа РО является также использование предварительных информационных обобщений, которые в [2] именуется, как рабочие (РИО).

Технологии ИИ существуют уже достаточно давно, но, в связи с быстрым развитием компьютерной отрасли, здесь можно увидеть некоторое отставание в освоении вновь открывающихся возможностей. Данное отставание можно использовать для быстрого достижения передовых рубежей в области КО при относительно небольших затратах.

Важно подчеркнуть, что для разработки компьютерных обучающих курсов (КОК), как правило, не требуется дорогое оборудование. И даже наоборот. Желательна ориентация на компьютеры, доступные по цене широким массам людей. Однако требуется тщательная и комплексная проработка вопросов, касающихся разных областей знаний: информатики, психологии обучения, технологии ИИ, специальных знаний по изучаемым дисциплинам. Это хорошо согласуется с возможностями российских вузов.

Тем не менее, отметим, что данная область стремительно развивается. Большой опыт в построении КОК накоплен в системах открытого дистанционного образования (ОДО). В этой системе работают некоторые отечественные и зарубежные вузы, предоставляя возможность получения образования вне стен вуза, как правило, с использованием интернет. В отечественных вузах эта форма развивается, обычно, как альтернатива заочному образованию. Но кроме этого, в силу указанных выше причин, накопленный здесь опыт полезен и для повышения эффективности обычного очного образования. Основными факторами повышения эффективности обучения с использованием таких КОК является:

- возможность обучения в удобные для обучаемого время и месте;
- возможность использованием оптимального графика занятий и их

чередования с отдыхом или работой;

- возможность установки индивидуального темпа проведения занятий;
- возможность многократного повторения как курса целиком, так и его отдельных частей;
- возможность изменения последовательности обучения и оптимизации ее для конкретного обучаемого;
- разнообразие форм представления материала и видов занятий.

Такие КОК по эффективности приближаются к индивидуальному обучению с преподавателем, и даже в чем-то превосходят их, поскольку в подготовке КОК участвует, как правило, коллектив из разных специалистов.

Узким местом большинства КОК является обратная связь с обучаемым в системе дозирования информационной нагрузки. Опытный преподаватель способен «интуитивно» чувствовать настроение обучаемого, его готовность к восприятию информации и оперативно корректировать ход занятия.

Для обеспечения такой обратной связи системе автоматизированного обучения (САО) необходимо находится в режиме постоянного распознавания образа состояния обучаемого, используя при этом модель состояния обучаемого (см. рис.).

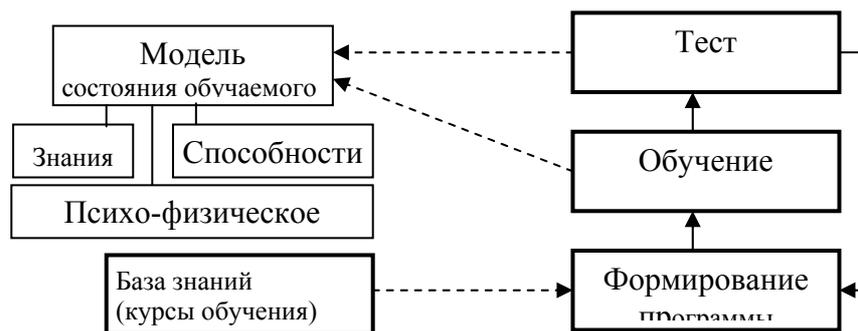


Рисунок. Автоматизированная обучающая система.

Данная модель неоднородна по своей структуре и может быть представлена, например, как совокупность трех моделей: модели знаний, модели способностей (к обучению) и модели психофизического состояния.

Модель знаний также представляет собой совокупность взаимосвязанных моделей, соответствующих разным предметам обучения. На основании результатов тестирования формируется прецедент, распознавание которого позволяет отнести обучаемого к тому или иному классу и построить для него соответствующую программу обучения. В процессе обучения также выполняется постоянный контроль и распознавание состояния обучаемого. Основанием для этого могут служить скорость ответов на вопросы, количество дополнительно запрашиваемой информации и другие факторы.

Гибкость в формировании обучающих программ достигается, прежде

всего, за счет использования баз знаний (БЗ). Здесь под БЗ будем понимать совокупность информации по изучаемым дисциплинам. Она может быть представлена, в частности, в виде совокупности КОК. В каждом из них может быть множество обучающих блоков (частей), образующих одну или несколько взаимосвязанных цепочек. Одна из них может представлять базовый курс, другие – облегченные или усложненные варианты.

Ввиду сложности описанной системы особое значение приобретают вопросы организации работ по ее созданию. В частности, представляется разумным растянуть процесс построения системы во времени, рассматривая задачу постоянного совершенствования, как неотъемлемую часть функционирования системы.

В целом, задача построения КОК представляется трудно формализуемой, т.к. связана с необходимостью учета человеческого фактора и касается различных областей знаний. Поэтому подходить к построению КО следует с позиции системного анализа. Изложенные подходы предполагается конкретизировать на примере КОК по тематике "Автоматизация", используемого для обучения студентов специальности "Химическая технология волокнистых материалов".

Литература

1. Журавлев Ю.И. Распознавание образов. Избранные научные труды. -М.: Магистр, 1998. -
2. Романов В.Е. Информационные обобщения - теоремы, принципы, алгоритмы, как практическая основа формирования конкретизированных систем распознавания образов. //Искусственный интеллект, Национальная академия наук Украины, Институт проблем искусственного интеллекта 2002.

Сочетание регулярных и эвристических подходов в прогнозировании свойств химических нитей в поле технологических факторов

Р.Р. Саакян, Н.К. Жиганов, И.А. Шпехт

(Благовещенск, Тверь)

Работа посвящена теории распознавания, прогнозирования и классификации трудноформализуемых непрерывнозначных технологических задач (ТНТ задач).

Ряд аспектов методологического обеспечения решения ТНТ задач, изложенных в работе, носят общеприменимый характер для различных технологических задач, в то время как основные иллюстративные материалы даны применительно к производству химических нитей.

Задачи формализации здесь являются трудными уже потому, что химическая нить отличается сложной внутренней структурой

(молекулярной, надмолекулярной и микроструктурой) [1]. Тем не менее, есть основания для реализации формализации – при отработанной технологии, получается в определенной степени стабильный продукт [2].

Причем для рассмотрения трудноформализуемых непрерывнозначных технологических задач требуется системный подход. Под системой понимаем объект исследования - химическое волокно и его технология производства, которое приводит некоторому требуемому качеству волокна.

В работе в качестве базы выполненных разработок использовались:

теория распознавания образов [3], [4];

теория нечетких множеств, конкретно – логика антонимов[5].

Исходным положением теории распознавания образов является опора на реализованные экземпляры изучаемого объекта (прецеденты) и их свойства и характеристики. Это соответствует сути преодоления трудноформализуемости задач.

Вторая база – теория нечетких множеств. Здесь в качестве замены трудноформализуемости используется опыт и интуиция исследователя.

Логика антонимов с одной стороны опирается на традиционные подходы в решении логических задачах, а с другой стороны преимущество логики антонимов заключается в том, что она дает удобную для практического использования аналитику.

В логике антонимов в задачах формализации используются структурные схемы связи между факторами формования и потребительскими свойствами, через промежуточные свойства, названные в работе эвристически оцениваемые свойствами (ЭОС).

Данные схемы строятся в определенной степени на основе интеллектуального анализа причинно-следственных связей в объекте. Этот анализ заменяет процесс моделирование в условиях, когда указанные выше причинно-следственные связи не могут быть точно выражены классическими методами аналитически, описаны количественно, или их выражение в явном виде весьма затруднено. Рассматриваемые схемы были названы эвристическими структурными схемами (ЭСС) для описываемых свойств.

Рассмотрим конкретизацию применения логики антонимов для задачи прогнозирования поведения свойств и показателей качества готовой продукции в новой области изменения технологических параметров с ориентацией на технологию производства химических нитей.

Отличительной особенностью данного материала является то, что в развитие теории антонимов, в работе предлагается оперировать не оценками свойств и входных параметров (в данном случае – параметров формования), а непосредственно числовыми данными по указанным свойствам и параметрам.

Постановка задачи следующая.

До определенной области изменения входных переменных известны аналитические представления закономерностей зависимости потребительских свойств от параметров формования.

Требуется для новой области изменения параметров формования получить аналитическое представление закономерностей, основываясь с одной стороны на результаты предыдущих ячеек (назовем регулярное составляющее), путем прямой пролонгации этих результатов, а с другой стороны внесением изменения в эту пролонгацию (назовем интеллектуальное составляющее) с учетом мнения экспертов об изменении потребительского свойства в новой области изменения параметров формования.

В этом случае решение представляется в виде функции двух составляющих:

$$Y_{\mathcal{E}} = f(Y_P; Y_I),$$

где $Y_{\mathcal{E}}$ – эвристическая (регулярно-интеллектуальная) оценка данного выходного параметра; Y_P – регулярная оценка выходного параметра; Y_I – интеллектуальная оценка выходного параметра.

Опираясь на представления связей и аксиоматики в логике антонимов, в общем случае регулярная оценка имеет отклонения от предполагаемого точного решения из-за неучета взаимовлияния входных параметров при построении регулярной оценки выходного параметра.

Для устранения ошибок и учета возможных отклонений строится интеллектуальная оценка, основанная на опыте и прогнозных оценках экспертов относительно поведения выходного параметра в новой области, которая играет роль пополнения в новой прогнозируемой области недостающих экспериментальных данных.

В данном случае интеллектуальная оценка представлять собой добавки, которые в сумме с регулярной оценкой позволят получить искомую эвристическую (регулярно-интеллектуальную) оценку.

Интеллектуальная оценка формируется на основе следующих условий:

- равенство нулю интеллектуальных оценок на сформированных линейных направлениях входных переменных (обеспечивается выбором формы интеллектуальной функции принадлежности);
- учет мнения экспертов о взаимосвязи (взаимовлиянии) входных параметров при формировании выходного параметра (обеспечивается эвристическими структурными схемами, построенными по принципам логики антонимов);
- учет мнения экспертов о различии влияния входных параметров на выходной параметр (обеспечивается выбором формы интеллектуальной

функции принадлежности – углом наклона функции).

При наличии многих входных параметров задача решается аналогично, с учетом усложнения ЭСС для регулярной и интеллектуальной оценок.

Для более точной оценки влияния каждого входного параметра на поведение выходного параметра используются весовые коэффициенты

Литература

1. Перепелкин К.Е. Структура и свойства волокон//М.Химия-1985.-208с.
2. Саакян Р.Р. Системный анализ трудноформализуемых непрерывнозначных технологических задач. Диссертация на соискание ученой степени доктора технических наук. - Благовещенск:- 2002.- 260 с.
3. Журавлев Ю.И. "Распознавание образов", в книге "Избранные научные труды", издательство "Магистр", М., 1998.
4. Загоруйко Н.Г. Прикладные методы анализа данных. Новосибирск: изд-во Ин-та математики, 1999. 270 с.
5. Голота Я.Я. Непрерывнозначная логика. - Л., 1982. - Деп. В ВИНТИ 14.10.82.

Алгоритм классификации химических нитей на основе аналитических представлений зависимостей свойств нити от факторов формирования

Р.Р. Саакян, Е.Г. Маежов, В.В. Сигачева, С.Н. Бобрышев

(Благовещенск, Санкт-Петербург, Тверь)

В настоящее время во многих областях науки и техники актуальным является решение задач, именуемых трудноформализуемыми, в части составления описаний свойств и характеристик исследуемых объектов, и требующих для преодоления трудностей формализации применения системного подхода, в том числе и современных методов обработки информации.

Ряд аспектов методологического обеспечения решения трудноформализуемых непрерывнозначных технологических (ТНТ) задач, изложенных в статье, носят общеприменимый характер для различных технологических задач, тем не менее, иллюстрация материала дана применительно к производству химических нитей.

Рассматриваемую в статье задачу выделения классов для ТНТ объектов можно разделить на следующие подзадачи:

- разработку схемы представления непрерывного признакового пространства в виде, удобном для учета его многомерности и использования конструктивной методики составления аналитических представлений закономерностей (АПЗ) для свойств – признаков объектов исследования;
- создание указанной конструктивной методики составления АПЗ;
- разработка общей методологии решения ТНТ задач на базе теории

распознавания образов с учетом многомерности и непрерывности признакового пространства. При этом требуется расширить область применения ТРО. Данное расширение относится ко всем этапам методологии:

- к обработке первоначальной, например, экспериментальной информации с опорой на разработанную информационную ориентирующую схему (ИОС) сокращения объема требуемых прецедентов;
- к составлению АПЗ изменения переменных;
- к определению классов объектов, включая и случаи сложных форм АПЗ и др.

Предложенный в статье метод составления АПЗ предназначен для получения закономерностей на основе экспериментальных данных, с ориентацией на значения функции в узловых точках сетки линейных направлений [1]. Метод разработан для работы с непрерывными признаками, которые наиболее характерны для технологических объектов исследования.

В данной работе совместно используются методы линейных направлений и согласующих функций [2], объединенные в единый метод ЛН-СФ.

Метод отличается следующими особенностями:

- опирается на относительно малые объемы экспериментальных данных;
- ориентирован на использование гармонических функций при получении аналитических зависимостей выходных параметров от входных; целесообразность применения указанного подхода для приближенных аналитических представлений функций, близких к гармоническим, является общепризнанной;
- применим для большого разнообразия множеств прецедентов, в том числе имеющих несферические и другие более сложные формы распределения.

В данной статье рассматриваются алгоритмы, разработанные для случаев, когда объекты отличаются наличием непрерывных (количественных) признаков, измеряемых в абсолютных величинах, шкалах интервалов и отношений.

Одна из отличительных особенностей трудноформализуемых задач, в частности задач с непрерывными изменениями признаков, заключается в наличии большого набора переменных, определяющих свойства объектов.

Можно принять, что признаки, характеризующие объекты, могут быть разделены на две категории – входные и выходные. Например, для технологических процессов, параметры, определяющие данную технологию, будут являться входными, а показатели, определяющие свойства и качественные характеристики выходного продукта – выходными. Эта особенность характерна для рассматриваемых в работе случаев.

Как следует из вышесказанного, область признаков вообще и по входу в частности будет представлять собой некоторую область в многомерном пространстве. В качестве такой области по входным переменным удобно использовать область в декартовом пространстве, в системе координат которого заданы узловые точки, расстояние между которыми определяется типом и условиями производства. Эти условия, в свою очередь, определяют и область выходных переменных.

Для решения представленной задачи выделения классов разработаны алгоритмы и создан программный продукт для решения задач распознавания, прогнозирования и классификации (алгоритмы РПК) применительно к трудноформализуемым технологическим объектам исследования. Исследовался случай непрерывнозначных переменных (признаков).

Алгоритм (при заданных диапазонах изменения входных признаков) на основе эмпирических (применительно к технологическим задачам – экспериментальных) данных «объект - признак» выделяет классы объектов, соответствующие сочетанию значений по всем выходным признакам, удовлетворяющий условиям:

$$\underline{Y}_i \leq Y_i \leq \overline{Y}_i \quad (1)$$

где Y – рассматриваемый выходной признак, $i = \overline{1, k}$,

$\underline{Y}_i, \overline{Y}_i$ – нижнее и верхнее значения признака.

Для каждого признака составляется ряд значений (градаций), в диапазоне которых должен находиться соответствующий признак для каждого выделяемого класса.

При наличии аналитических представлений закономерностей (АПЗ) для выходных признаков, по предложенным алгоритмам РПК еще более удобно выделять классы объектов.

Для трудноформализуемых технологических задач с непрерывнозначными признаками, разработанные в работе алгоритмы РПК используют предложенную в данной статье конструктивную методологию составления АПЗ связи между входными и выходными признаками, именуемую методом линейных направлений - согласующих функций (метод ЛН-СФ). В этом случае, на основе экспериментальных данных строятся соответствующие АПЗ для каждого выходного признака, а затем определяются области выходных признаков, которые образуют данный класс.

На основе полученных АПЗ удастся выделить классы объектов, соответствующие сочетанию значений различных признаков, каждый из которых соответствует своим пределам изменения.

В качестве границ классов целесообразно выбирать гиперплоскости в

пространстве признаков, каждая из которых соответствует постоянному значению одного какого-либо входного признака. Это приводит к образованию ступенчатых границ классов.

Литература

1. Романов В.Е., Климов В.А., Саакян Р.Р. К развитию информационных технологий в области технологии химических волокон// Вестник Санкт-Петербургского государственного университета технологии и дизайна. 2001. № 5. С. 95-109
2. В. В. Сигачева Задачи идентификации функций многих переменных в системах автоматизации красильно-отделочных производств// В кн. "Проектирование систем автоматизации технологических процессов в красильно-отделочном производстве" Под ред. В. А. Климова. М.: Легпромбытиздат, 1989.

Схема динамического построения многоуровневого описания изображений

С.Ю. Сергунин, К.М. Квашинин, М.И. Кумсков

(Москва)

Введение

Решение задачи распознавания изображений требует построения «правильного» описания объектов, содержащего необходимую для их распознавания информацию. При формировании такого описания, часть информации об объекте теряется, поэтому возникает необходимость динамического построения описаний, в соответствии с «требованиями» распознаваемых объектов. Предлагается структурная схема системы распознавания сцен, основанная на использовании моделей распознаваемых объектов [1], которые управляют процессом динамического построения описания сцены.

Определения и постановка задачи

Сцена (Sc) – это некоторая совокупность трехмерных объектов (O_1, \dots, O_n) в трехмерном пространстве. Модель OM_i объекта O_i представляет собой отдельный компонент системы [2], инкапсулирующий многоуровневое описание объекта и обладающий возможностью сравнивать описание своего объекта с внешним представлением, соответствующим «первоначальному эскизу» Марра.

Процесс обучения системы состоит в построении моделей OM_1, \dots, OM_n объектов O_1, \dots, O_n . После обучения система проводит распознавание объектов на трехмерной сцене Sc по ее проекциям Psc . Результатом распознавания является:

1. Выделение на сцене S_c областей отдельных объектов O_1, \dots, O_n на уровне фона.
2. Распределение объектов O_1, \dots, O_n по известным классам, то есть сопоставление объекту O_i некоторой модели OM_i , которая уже имела в базе моделей объектов OMDB. Также возможным результатом является отказ от распознавания.

Таким образом, процесс распознавания можно разделить на две основные стадии:

1. Выбор активной модели OM^* объекта из OMDB.
2. Подтверждение активной модели за счет формирования дополнительных представлений изображения.

При распознавании после первичного анализа изображения P выбирается одна из моделей OM^* , которая на данный момент более других соответствует изображению. Модель OM^* становится активной и начинает сама «управлять процессом описания». Основная цель этого процесса состоит в подтверждении соответствия активной модели объекту, представленному на сцене. Схема подтверждения модели содержится в самой модели, определяется при ее построении и включает в себя набор критических особенностей, без подтверждения которых нельзя говорить о правильности выбора модели. Вариант такого алгоритма «подтверждения» описан в [3]. Управление описанием состоит в формировании таких параметров построения описания сцены, чтобы описание подтверждало наличие у рассматриваемого объекта тех особенностей, которые являются критическими для данной модели OM^* .

Для эффективного сравнения изображений они представляются в виде набора особых точек (Singular Points - SP), с маркерами, соответствующими типам особых точек. Набор типов особых точек определяется алфавитом элементов описания (DEA). Алфавит содержит индикаторную функцию $Ind(.)$, которая идентифицирует особые точки. В процессе распознавания на изображении выделяются особые точки, затем они классифицируются по типам. Таким образом, описание изображения представляется набором особых точек $\{SP\}$. Для рассмотрения процесса построения такого описания, определим структуру системы распознавания.

Структура системы

Структуру системы можно представить в виде набора блоков, каждый из которых обладает собственной функциональностью и решает определенный набор задач [4]. Система состоит из четырех внутренних блоков и сканирующего модуля, который снимает проекцию сцены, для ее последующей обработки системой.

Блоки системы:

1. Блок управления (Control Block - CB);

2. Блок анализа (Analysis Block - AB);
3. Сенсорный блок (Sensor Block -SB);
4. Блок моделей объектов (Model Block - MB);
5. Сканирующий модуль (Scanner).

Рассмотрим более подробно функции каждого блока.

1. Блок управления (CB) содержит активную модель OM^* и формирует параметры запросов к сенсору для получения нового окна изображения (фрейма), к блоку анализа на поиск и классификацию SP в соответствии с алфавитом DEA.
2. Блок анализа (AB) занимается классификацией особых точек на разных уровнях детализации проекций сцены. Он получает от CB алфавит 'элементов описания DEA и возвращает ему набор маркированных особых точек. При этом он формирует запрос в SB, передавая $Ind(.)$ и уровень детализации проекции как параметры описания SP и получая найденные особые точки.
3. Сенсорный блок SB ищет особые точки на получаемом от AB уровне детализации проекции с помощью индикаторной функции Ind .
4. Блок моделей MB получает набор маркированных особых точек и определяет список моделей из OMDB, соответствующих этому набору.
5. Сканер – это компонент системы, которому задаются параметры сканирования сцены (параметры фрейма) и он строит изображение.

Схема построения описания

Сканер создает фрейм и через определенные промежутки времени и передает его в AB. Блок анализа раскладывает изображение на уровни детализации [2] и передает их в SB. При этом он задает индикаторную функцию $Ind(.)$ в соответствии с заданным алфавитом DEA. Блок AB, используя текущую индикаторную функцию $Ind(.)$, проводит поиск SP на заданном уровне детализации проекции, где они классифицируются и маркируются. Затем список маркированных особых точек $\{SP_j\}$ поступают в MB, который организует поиск «лучшей» модели OM в БД OMDB. Найденная модель становится активной. Она задает алфавит DEA блоку анализа и параметры сканирования сцены в соответствии с алгоритмом «подтверждения» объекта.

Заключение

Предлагаемая схема динамического построения описаний создана для анализа непрерывного потока проекций сцены. Если в качестве сканирующего модуля использовать цифровую видеокамеру, то поток данных от нее будет непрерывно обрабатываться. При необходимости производится автоматическая подстройка параметров съемки. В результате предлагаемая схема может использоваться в системах машинного зрения, для работы в реальном времени.

Литература

1. Мэпп Д. Зрение. Информационный подход к изучению представления и обработки зрительных образов // М.: Радио и связь, 1987 г.
2. Sergunin S.Yu., Kvashnin K.M., Kumskov M.I. Using Image Representation Families for Recognition Based on Symbol Marking of Singular Points //Pattern Recognition and Image Analysis, 2003, 13, N.3, p. 531-538.
3. Кумсков М.И. , Сергунин С.Ю. , Квашнин К.М. Итерационное формирование описаний изображения, управляемое моделью объекта, в задаче распознавания // Настоящий сборник.
4. Kumskov M.I. Calculation Scheme of the Image Analysis Controlled by the Models of the Objects to be Recognized //Pattern Recognition and Image Analysis, 2001, 11, N2, p. 446–449.

Процедура парного элайнмента для автоматического оценивания качества систем оптического распознавания текста

О.С. Середин, А.В. Скоркин
(Тула)

Введение

Современные коммерческие системы распознавания текста (optical character recognition systems, OCR-системы) (FineReader, www.abbyu.ru; QneiForm, www.cognitive.ru) показывают высокие результаты, широко применяются, хорошо себя зарекомендовали. Разработчики подобных систем вплотную подошли к решению проблемы распознавания рукописных символов. Помимо непосредственно самого распознавания, с тем либо иным успехом решаются задачи document-analysis, а именно, интеллектуальное вычленение из графических изображений документов таблиц, рисунков, графиков, автоматическая расстановка стилей, распознавание заполненных форм и т.д. Речь идет уже об (Intelligent Character Recognition) ICR-системах.

Основное внимание в данной работе уделяется прикладной задаче специфического вида, требующей применения OCR-систем. Для построения системы тестирования разрабатываемого программного обеспечения (AutomatedQA Test Complete, www.automatedqa.com; Mercury Interactive LoadRunner, www.mercuryinteractive.com) оказывается удобно иметь систему OCR специфического типа (Texttract, www.structurise.com). Ставится задача поиска и распознавания текста на изображении, полученном копированием области экрана ЭВМ (окно некоторой программы, меню, окно диалога). На вход системы поступает графический объект, так называемый кадр (screenshot), всей области отображения или ее фрагмента. В результате работы системы формируется массив символов (элементов текста), найденных на обрабатываемом кадре. Такая информация может

использоваться в дальнейшем системой тестирования ПО, например, для контроля качества вывода в информационные панели или для управления элементами интерфейса.

Специфика такой задачи, заключается в том, что текст в подобных изображениях представляет собой идеальные символы, выведенные одним из шрифтов (обычно True Type), установленных в ОС, что безусловно облегчает задачу по сравнению с распознаванием сканированных изображений. Однако имеются особенности, осложняющие эту задачу: 1) цвет шрифта, даже в пределах одной строки может быть разным, 2) фон как правило представлен несколькими цветами, 3) в анализируемом изображении может быть несколько смысловых фрагментов. Известные системы общего применения справляются с решением подобной задачи неэффективно, кроме того, лицензия на включение их ядра в прикладное ПО достаточно дорога.

Авторами совместно с Тульским отделением компании AutomatedQA (www.aqa.com.ru) разрабатывается OCR-система BMP2Text, решающая задачу поиска и распознавания текста на кадрах графических элементов интерфейса пользователя.

Система BMP2Text представляет собой программно алгоритмический комплекс, решающий следующие подзадачи:

1. Выделение прямоугольных фрагментов на изображении
2. Бинаризация цветного фрагментированного изображения
3. Выделение строк на изображении
4. Выделение отдельных символов в строках
5. Обучение и распознавание отдельных символов
6. Распознавание подчеркнутых символов
7. Расстановка пробелов между словами
8. Контекстный анализ для коррекции результатов предварительного распознавания

При более-менее успешном решении задачи распознавания встает вопрос об оценке качества распознающей системы. Оценивать качество алгоритмов необходимо по достаточно большому числу картинок. На качество распознавания влияет успешность решения любой из 8 подзадач, перечисленных выше. Алгоритмы решения указанных подзадач могут настраиваться конкретными параметрами. Кроме того, в процессе создания системы вообще могут быть допущены логические и программные ошибки. Все это ведет к тому, что проводить визуальный контроль качества алгоритмов невозможно. Тестировщик должен, изменив какой-нибудь из параметров системы, осуществить прогон по десяткам картинок и зафиксировать в специальном журнале ошибки OCR-системы.

Для автоматического оценивания качества работы OCR-систем предлагается следующая схема. Для каждого графического изображения

тестировщик подготавливает эталонный, идеальный текстовый файл его содержимого. Сделать это можно как полностью вручную, так и «подправив» результаты представленные предварительным прогоном OCR-системы. Таким образом, каждому графическому файлу соответствует эталонный файл «результатов распознавания глазами». При обработке изображения системой распознавания генерируется рабочий текстовый файл результатов автоматического распознавания. Сравнивая результаты распознавания, хранящиеся в эталонном файле и рабочем можно судить о качестве работы OCR-системы. Таким образом можно сравнивать результаты работы как одного алгоритма, используя разные параметры, так и несколько совершенно разных OCR-систем. Однако, для того чтобы полностью автоматизировать этот процесс надо иметь инструмент автоматического сравнения текстовых документов, а в конечном счете текстовых строк (буферов).

Применение процедуры парного элайнмента для автоматического оценивания качества OCR-систем. Оценка качества по элайнменту

Для сравнения текстовых строк предлагается использовать широко известную в биоинформатике процедуру парного элайнмента (выравнивания) двух последовательностей элементов конечного алфавита. Сущность процедуры парного элайнмента заключается в следующем.

Пусть имеется две конечных последовательности элементов некоторого алфавита. Необходимо путем введения вставок (дополнительный элемент алфавита, в англоязычной литературе называемый «gap») добиться того, чтобы последовательности стали одинаковой длины. Выровненные последовательности, записанные одна под другой, будем называть версией элайнмента. При этом существует набор правил, которые определяют возможность нахождения пары символов в позиции (столбце) элайнмента. Например, запрещено нахождение в одной позиции двух вставок.

Пример:

Hello, World!	эталонный текст
Nella, VVorId!	текст, распознанный OCR

Две различные версии элайнмента (знаком «#» помечены позиции, в которых имеется несоответствие символов):

Hello, W-orld!	H-ello-, W--or-ld!
Nella, VVorId!	-Nell-a, -VVorI-d!
# # ## #	## ## ### ##

В биоинформатике хорошо известны методы поиска наилучшей версии элайнмента аминокислотных последовательностей [2,3]. Они опираются на матрицы взаимных соответствий аминокислот (элементов конечного алфавита), и на модель открывающих и продолжающих вставок. В работе

предлагается критерий для поиска парного элайнмента в форме парно-сепарабельной целевой функции. Механизм использования процедуры динамического программирования для оптимизации функций подобного вида детально описан в [1].

Когда версия элайнмента получена, то оценкой качества распознавания OCR-системы может служить величина $Q = \frac{L-E}{L}$, где L – длина элайнмента, E – число позиций элайнмента, в которых имеются несовпадающие элементы. Для примеров имеем: $Q_1 = \frac{14-5}{14} = 0.648$, $Q_2 = \frac{18-9}{18} = 0.5$. Для идеально распознанного текста величин $Q = 1$. Если же в результате выравнивания нет столбцов с одинаковыми элементами, то $Q = 0$.

Применение процедуры блочно-локального элайнмента для сравнения результатов распознавания структурированного изображения

Часто оказывается, что для распознавания представлено изображение состоящее из нескольких непересекающихся фрагментов. Причем автоматическое выделение фрагментов не представляет затруднений. Например, на изображении на рис. 1 можно выделить до 7 фрагментов. При составлении эталонной строки тестировщик может пользоваться либо четким (формальным) либо интуитивным алгоритмом «обхода» фрагментов. Не гарантированно, что OCR-система будет формировать строку результатов распознавания, обходя фрагменты в той же последовательности.

На рис. 2а первая строка представляет собой условную эталонную строку, а вторая – результат, сформированный OCR-системой-№1. На рис. 2б первая строка – все та же эталонная строка, а вторая – результат, сформированный OCR-системой-№2.

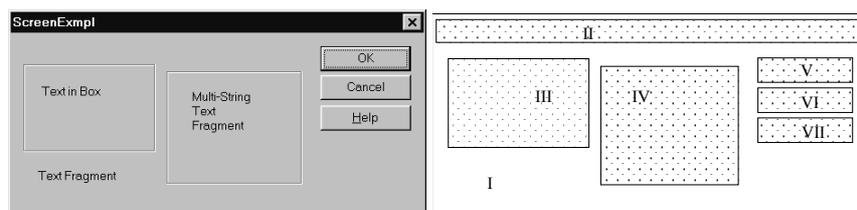


Рис. 1

- а) ScreenExmpl Text in Box Multi-String Text Fragment Text Fragment OK Cancel Help
ScreenExmpl OK Cancel Help Text in Box Multi-String Text Fragment Text Fragment
- б) ScreenExmpl Text in Box Multi-String Text Fragment Text Fragment OK Cancel Help

ScreenExmpl Text Fragment OK Text in Box Multi-String Text Fragment Cancel Help

Рис. 2

Как видим, обе системы идеально справились с задачей распознавания текста внутри фрагментов. Но из-за того, что OCR-системы использовали тактику обхода фрагментов, отличную от той, которая использовалась при составлении эталонной строки качество элайнмента, оцененное по критерию, предложенному выше будет крайне низким:

```
ScreenExmpl----- Text in Box Multi-String Text Fragment Text Fragment OK Cancel Help
ScreenExmpl OK Cancel Help Text in Box Multi-String Text Fragment Text Fragment-----
```

$$Q_1 = 0.61$$

```
ScreenExmpl----- Text in Box Multi-String Text Fragment Text Fragment OK Cancel Help
ScreenExmpl Text Fragment OK Text in Box Multi-String Text Fragment -----Cancel Help
```

$$Q_2 = 0.57$$

Таким, образом, необходима процедура сравнения текстовых строк, осуществляющая «классический» элайнмент внутри поставленных друг другу в соответствие фрагментов. Пример, установления такого соответствия приведен на рис.2 разными способами подчеркивания.

Литература

1. Mottl V.V., Muchnik I.B. Bellman functions on trees for segmentation, generalized smoothing, matching and multi-alignment in massive data sets. DIMACS Technical Report 98-15, February 1998. Center for Discrete Mathematics and Theoretical Computer Science, Rutgers University, USA, 63 P.
2. Pearson W.R. and Lipman D.J. Improved tools for biological sequence analysis. PNAS, 1988, 85, 2444- 2448.
3. Pearson W.R. Rapid and sensitive sequence comparison with FASTP and FASTA. Methods in Enzymology, 1990, 183, 63-98.

Метод нейросетевого формирования инвариантных к повороту признаков для распознавания двумерных изображений

Ю.Г. Сосулин, Фам Чунг Зунг
(Москва)

Введение

Согласно [1,2] для выделения признаков, инвариантных к повороту, нужно преобразовать исходное изображение в «круговое» с использованием круговой решетки, которая образована разбиением круга на одинаковые кольца и сектора, и затем сформировать соответствующие веса нейронов инвариантной нейронной сети (ИНС). Главный недостаток этого метода: размер клеток решетки с удалением от центра увеличивается, соответственно уменьшается способность правильного отображения мелких

деталей изображения и ухудшается различимость выходных сигналов ИНС. Поэтому эффективность распознавания снижается. Для частичного преодоления указанного недостатка можно использовать круговую решетку с большим числом секторов. Однако, при этом размер вектора изображения, и число нейронов ИНС увеличиваются. Здесь мы предлагаем новый метод построения «кругового» изображения и соответственно создания весов нейронов ИНС, формирующей инвариантные признаки. При этом структура и количество нейронов ИНС остаются таким же, как и при методе [1, 2]. Предлагаемый метод, как показано в данной работе, существенно повышает эффективность распознавания изображений.

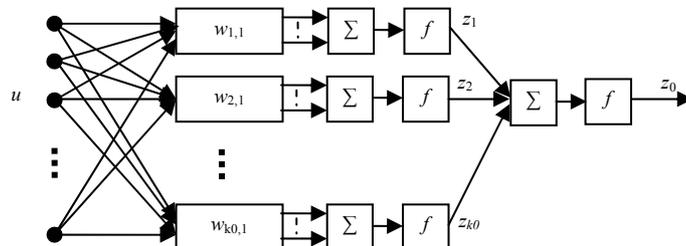
Создание вектора «кругового» изображения и весов нейронов ИНС

«Круговое» изображение получается наложением специальной круговой решетки на квадратное дискретизированное изображение и суммированием пикселей, оказавшихся в клетках этой решетки. Центр решетки должен совпадать с центром изображения, а её радиус равен расстоянию от центра до наиболее удалённой части изображения. Значения клеток, находящихся вне квадратного изображения, полагаются равными нулю. Первоначальные клетки решётки, образованные секторами и круговыми кольцами, дополнительно разбиваются на более мелкие клетки, число которых k_j зависит от номера кольца $j=1,2,\dots,p$. Число первоначальных клеток одного кольца совпадает с числом секторов $k_0=360/\varphi$ и определяется заданным значением угла поворота изображения φ , для которого ИНС должна формировать инвариантные признаки. Таким образом, число клеток j -го кольца равно $k_0 k_j$. Клетки одного кольца имеют одинаковый размер. Первое «кольцо» представляет собой круг, число клеток которого равно k_1 . Число колец p и их ширина выбираются экспериментально с учётом априорной информации о форме объектов. Итак, число клеток в рассматриваемой

решетке $l = k_0 \sum_{j=1}^p k_j$. Поскольку $k_j > 1$, число клеток этой круговой

решетки больше, чем при создании решётки методом [1,2], при этом способность отображения мелких деталей увеличивается. Вектор «кругового» изображения – это вектор, составленный из значений клеток построенного «кругового» изображения, перенумерованных последовательно от p -го (внешнего) кольца до 1-го (круга).

ИНС включает в себя набор нейронных «пластин», структура которых одинакова и показана на рисунке; $w_{1,1}, w_{2,1}, \dots, w_{k_0,1}$ – векторы весов нейронов первой пластины; f - сигмоидная функция активации нейрона.



Структура нейронной пластины

Количество нейронов каждой пластины равно числу секторов k_0 круговой решетки. Размер вектора весов $w_{1,1}$ первого нейрона первой пластины совпадает с размером вектора «кругового» изображения (l), а значения элементов выбираются случайным образом. Этот вектор разделяется на p подгрупп, каждая из которых состоит из $k_j k_0$ ($j=1,2,\dots,p$) элементов. Циклическим перемещением элементов каждой подгруппы вектора $w_{i-1,1}$ на k_j мест, находим векторы $w_{i,1}$ ($i = 2 \dots k_0$). Выходной сигнал первой

пластины (см. рисунок)
$$z_0 = f\left(\sum_{i=1}^{k_0} z_i\right) = f\left(\sum_{i=1}^{k_0} f(u^T \cdot w_{i,1})\right)$$
. При

повороте изображения на угол φ элементы вектора «кругового» изображения перемещаются циклически на k_j мест. Благодаря указанному выбору векторов весов нейронов значения z_1, z_2, \dots, z_{k_0} также циклически перемещаются, но их сумма не изменяется. Таким образом, выходной сигнал пластины не изменяется при повороте изображения на угол φ . Элементы векторов весов первых нейронов на следующих пластинах $w_{1,2}, w_{1,3}, w_{1,4}, \dots$ выбираются случайным образом. Векторы весов остальных нейронов на этих пластинах создаются тем же способом, что и для нейронов первой пластины. Инвариантность к повороту на меньшие углы достигается при увеличении числа секторов круговой решетки и соответственно числа нейронов в пластине.

Экспериментальные результаты

В качестве исходных данных использовались изображения пяти различных самолётов (B1, F117A, VF22A, MIG29, RAFAL). Предварительная обработка осуществлялась аналогично [3, 4], но с добавлением блока формирования вектора «кругового» изображения вышеуказанным методом. Этот вектор подавался на ИНС, выходные сигналы которой, поступали на нейросетевой классификатор (трёхслойный персептрон). Классификатор обучался алгоритмом Флетчера-Ривса. Эксперименты проведены на компьютере Celeron 733 с ОЗУ 128 Мбайт. В результате показано, что при использовании предлагаемого метода

формирования инвариантных признаков вероятность правильного распознавания повышается существенно - на (5-10)% по сравнению с методом [1, 2]. Время обучения и время распознавания практически не изменялись. По сравнению с использованием в качестве инвариантных к повороту признаков моментов Зернике и псевдо-Зернике [3] время распознавания значительно уменьшается: в 40 – 70 раз при заданной вероятности правильного распознавания. Однако структура системы распознавания сложнее, эффективность работы в условиях шума меньше и необходимое число изображений в обучающей выборке больше (в 2 раза).

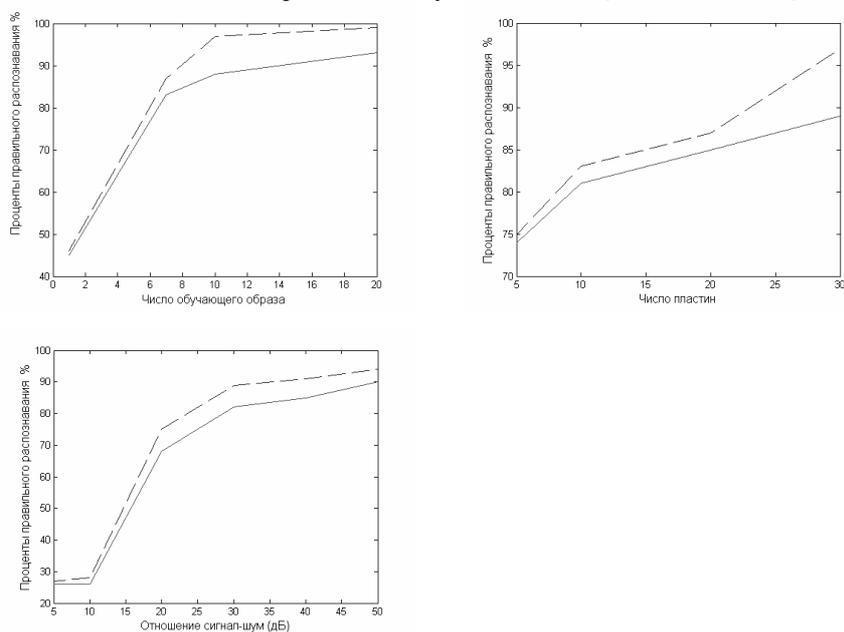


Рис. 3. Зависимость вероятности правильного распознавания

а) от числа обучающего образа; б) от числа пластин; в) от отношения сигнал-шум.

Литература

1. Fukumi M., Omatu S., Takeda F. Rotation-invariant neural pattern recognition system with application to coin recognition // IEEE Trans. 1992. V. NN-3. No.2. P. 272-278.
2. Томашевич Н.С, Томашевич Д.С, Галушкин А.И. Метод реализации инвариантности к аффинным преобразованиям при распознавании двумерных изображения // Информационные технологии. 2001. Приложение к журналу. №1. С. 16-17.
3. Сосулин Ю.Г., Фам Чунг Зунг. Нейросетевое распознавание изображений с использованием моментов Зернике и псевдо-Зернике //

- Труды межд. конф. РОАИ-6. Великий Новгород. 2002. Т.2. С. 529-533.
4. Сосулин Ю.Г., Фам Чунг Зунг. Анализ нейросетевого распознавания изображений в условиях шума и неопределенности ракурса // Труды межд. конф. DSPA-2003. Москва. 2003. Т.2. С. 619-622.

Программный комплекс MRIAN для обработки МЭГ головного мозга и локализации дипольных источников магнитного поля на МРТ

В.В. Сычев, М.Н. Устинин
(Пушино)

Общие сведения

MRIAN представляет собой графическую среду для визуализации и анализа магнито-резонансных томограмм (МРТ) головного мозга и магнитоэнцефалограмм (МЭГ).

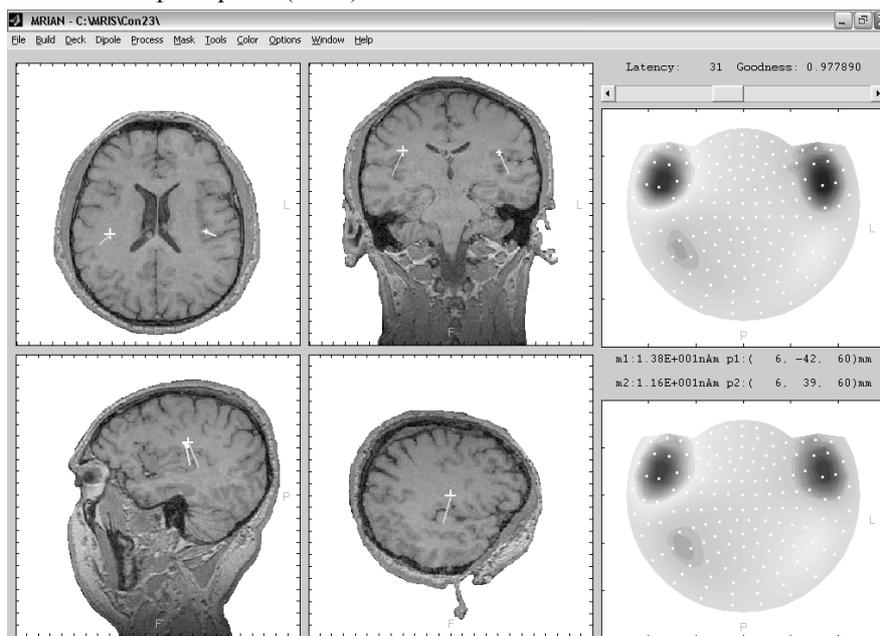


Рис. 1. Внешний вид MRIAN.

MRIAN позволяет выполнять:

- чтение файлов с МРТ, МЭГ и временными рядами,
- удаление из МЭГ каналов с артефактами,
- выбор произвольного участка данных для детального анализа,
- выделение полезного сигнала из МЭГ,

- амплитудное картирование МЭГ на поверхности головы и модельной МЭГ,
- пространственную локализацию источников магнитного поля в рамках одно- или двухдипольной модели,
- построение аксиальных и тангенциальных томографических срезов головного мозга с отображением точечных диполей,
- оценку достоверности найденных дипольных источников,
- хранение и распечатку получаемых изображений,
- запись видеороликов по результатам работы.

Решение прямой задачи магнитной энцефалографии

Прямая задача магнитной энцефалографии состоит в нахождении магнитного поля по известным источникам. Источники магнитной активности головного мозга моделируются точечными токовыми диполями. Каждый такой диполь характеризуется двумя векторами: \mathbf{r}_0 – радиус-вектор диполя (положение диполя) и \mathbf{Q} – вектор, задающий направление и силу диполя (момент диполя). Для вычисления магнитной индукции на поверхности головы используется модель токового диполя в проводящей сфере. Для датчика магнитного поля, находящегося в точке \mathbf{r} и имеющего направление \mathbf{n} , уравнение записывается следующим образом

$$B(\mathbf{r}_0, \mathbf{Q}) = \frac{\mu_0}{4\pi F^2} ((F(\mathbf{Q} \times \mathbf{r}_0) - (\mathbf{Q} \times \mathbf{r}_0, \mathbf{r})\nabla F), \mathbf{n}),$$

здесь $F = a(ar + r^2 - (\mathbf{r}_0, \mathbf{r}))$,

$$\nabla F = (a^2 r^{-1} + a^{-1}(\mathbf{a}, \mathbf{r}) + 2a + 2r)\mathbf{r} - (a + 2r + a^{-1}(\mathbf{a}, \mathbf{r}))\mathbf{r}_0,$$

$$\mathbf{a} = \mathbf{r} - \mathbf{r}_0, \quad a = |\mathbf{a}|, \quad r = |\mathbf{r}|, \quad |\mathbf{n}| = 1, \quad \mu_0 = 4\pi \cdot 10^{-7}.$$

Утверждение. Зависимость магнитной индукции от дипольного момента линейна.

Доказательство

$$\begin{aligned} B &= \frac{\mu_0}{4\pi F^2} ((F(\mathbf{Q} \times \mathbf{r}_0) - (\mathbf{Q} \times \mathbf{r}_0, \mathbf{r})\nabla F), \mathbf{n}) = \\ &= \frac{\mu_0}{4\pi F^2} ((F(\mathbf{Q} \times \mathbf{r}_0), \mathbf{n}) - ((\mathbf{Q} \times \mathbf{r}_0, \mathbf{r})\nabla F, \mathbf{n})) = \\ &= \frac{\mu_0}{4\pi F^2} (F(\mathbf{Q} \times \mathbf{r}_0, \mathbf{n}) - (\mathbf{Q} \times \mathbf{r}_0, \mathbf{r})(\nabla F, \mathbf{n})) = \end{aligned}$$

$$\begin{aligned}
&= \frac{\mu_0}{4\pi F^2} (F(\mathbf{Q}, \mathbf{r}_0 \times \mathbf{n}) - (\mathbf{Q}, \mathbf{r}_0 \times \mathbf{r})(\nabla F, \mathbf{n})) = \\
&= \frac{\mu_0}{4\pi F^2} ((\mathbf{Q}, F(\mathbf{r}_0 \times \mathbf{n})) - (\mathbf{Q}, (\nabla F, \mathbf{n})(\mathbf{r}_0 \times \mathbf{r}))) = \\
&= \left(\frac{\mu_0}{4\pi F^2} (F(\mathbf{r}_0 \times \mathbf{n}) - (\nabla F, \mathbf{n})(\mathbf{r}_0 \times \mathbf{r})), \mathbf{Q} \right) = (\mathbf{K}, \mathbf{Q}).
\end{aligned}$$

Таким образом, мы переписали уравнение для магнитной индукции в виде скалярного произведения $B = (\mathbf{K}, \mathbf{Q})$, где

$$\mathbf{K} = \frac{\mu_0}{4\pi F^2} (F(\mathbf{r}_0 \times \mathbf{n}) - (\nabla F, \mathbf{n})(\mathbf{r}_0 \times \mathbf{r})).$$

Это и доказывает наше

утверждение. Дополнительно можно заметить, что вектор $\mathbf{K} \perp \mathbf{r}_0$.

Решение обратной задачи магнитной энцефалографии

Обратная задача магнитной энцефалографии состоит в нахождении источников магнитного поля по известным значениям магнитной индукции на некотором количестве датчиков, расположенных на поверхности головы. Для решения этой задачи минимизируется целевая функция, зависящая от источников магнитного поля

$$f = \sum_{i=1}^N w_i (B_i - B_i^0)^2 \rightarrow \min.$$

Здесь B_i^0 – значения магнитной индукции, измеренные датчиками, а B_i – соответствующие значения, полученные по найденным источникам магнитного поля, w_i – веса датчиков, N – количество датчиков. При этом источники магнитного поля естественно должны находиться внутри головы.

Начальное приближение задается пользователем в интерактивном режиме или находится автоматически из статистических соображений.

Положение диполей находится при помощи стандартных математических методов поиска локального минимума функции нескольких переменных. Поскольку в нашем случае очень сложно получить информацию о производных минимизируемой функции, выбор был сделан в пользу методов нулевого порядка. Конкретно применяется симплекс-метод Нелдера-Мида. Заметим, что наша целевая функция зависит только от $3d$ переменных, где d – количество диполей. Эти переменные определяют положение диполей. Зная положение диполей и помня о том, что магнитная индукция линейно зависит от моментов диполей, последние можно найти,

решая соответствующую систему линейных уравнений.

Работа поддержана проектами РФФИ №03-01-06273, №01-07-97060, №01-07-90317, №01-01-00894.

Быстрые алгоритмы выделения графических примитивов в задачах распознавания и сжатия контурных изображений

В.С. Терещенко, В.Е. Анциперов

(Москва)

Компания ABBYY (www.abbyy.ru)

Институт радиотехники и электроники РАН (www.cplire.ru)

В докладе обсуждается применение алгоритмов последовательной выборочной идентификации [1], [2] для задач распознавания и сжатия контурных изображений. В основе алгоритмов лежит анализ локальных параметров траектории и синтаксический синтез распознаваемого образа из соответствующих графических примитивов. Предполагается, что оперативная идентификация локальных характеристик траекторий контуров по заданной системе примитивов позволит эффективно использовать последовательные процедуры, контекстные критерии и т.д. для целей ранней диагностики и сужения подмножеств объектов распознавания/кодирования. На этой основе могут быть синтезированы системы сжатия и распознавания изображений более экономичные по сравнению с существующими и позволяющие значительно сократить количество вычислительных операций.

В докладе также обсуждаются технические вопросы реализации алгоритмов последовательной выборочной идентификации, связанные с концепциями древовидного описания распознаваемых в терминах признаков локальных особенностей этих линий, созданием банка данных для контурных образов на основе древовидной структуры и т.д. Особенное внимание уделено вопросам робастности (устойчивости) результатов распознавания при поворотах и сдвигах контурных образов, а также устойчивости к фоновым (шумовым) искажениям.

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований.

Литература

1. В.Е.Анциперов. Метод последовательной выборочной идентификации сигналов. Радиотехника и электроника. т.40, N 5, 1995.
2. В.Е.Анциперов. Оптимизирующее свойство метода последовательной выборочной идентификации. Радиотехника и электр. т.41, N 2, 1996.

Интегральные оценки исправности сложных систем по их обобщённым характеристикам

А.А. Тихонов

(Москва)

В настоящее время контроль исправности сложных систем в подавляющем большинстве случаев реализуется на основе анализа значений параметров определяющих динамические свойства систем с их последующей обработкой на ЭВМ. По результатам обработки принимается решение об исправности или неисправности сложной системы в целом.

В докладе предлагается осуществлять динамический неразрушающий контроль исправности сложных систем на основе интегральных оценок обобщённого показателя, который формируется основными динамическими параметрами.

В качестве обобщённого показателя сложной динамической системы целесообразно контролировать импульсную переходную характеристику этой системы, которая представляет собой реакцию системы на единичное импульсное воздействие при нулевых начальных условиях. Можно применить и специально выбранное типовое воздействие на систему в процессе работы [1]. В этих случаях реакция системы (переходный процесс) будут определяться всеми динамическими параметрами системы, которые требуют контроля.

Использование интегральных оценок специального типа позволит объективно оценивать текущие динамические свойства системы.

В качестве интегральных оценок целесообразно использовать различные метрики метрических пространств функционального анализа. С учётом того, что на выходной сигнал системы, как правило, будут накладываться высокочастотные помехи целесообразно в используемые для оценки метрики подставлять результаты аналитического описания номинального и текущего сигнала системы на основе ортогонального разложения сигнала по базису функций Лагерра. При этом правильный подбор масштабного коэффициента будет способствовать оптимальной фильтрации сигнала и получению требуемой точности описания наиболее коротким отрезком ортогонального ряда [2] за минимальное время.

Пример

В работе рассматривалась задача диагностики, сформулированная следующим образом. Пусть некоторая система в процессе работы выдаёт выходной цифровой сигнал, который для удобства представим функцией

$$\varphi(t) = k_1 e^{-\alpha_1 t} + k_2 e^{-\alpha_2 t} \sin wt + \varphi$$

Требуется, зная вид сигнала при нормальном функционировании системы $\varphi_0(t)$ и набор параметров, от которых зависит её

функционирование, оценить состояние системы в текущий момент. Допускается, что на выходной сигнал системы накладываются высокочастотные помехи. Этапы диагностики:

1. Вычисление оптимального масштабного коэффициента m разложения по базису из ортонормированных функций Лагерра:

$$l_n(mt) = \sqrt{m} e^{-0.5mt} \sum_{k=0}^n \frac{n! (-mt)^k}{(n-k)! k! k!}$$

Правильный выбор масштабного коэффициента обеспечивает требуемую точность разложения при минимальном числе членов ряда.

Вычисление коэффициентов разложения A_n сигнала $\varphi(t)$ по выбранному базису $\{l_n(m_{onm}t)\}$

$$\varphi(t) \approx \tilde{\varphi}(t) = A_0 l_0(t) + A_1 l_1(t) + \dots + A_n l_n(t)$$

$$A_i = \int_a^b \varphi(t) l_i(t) dt, \quad i = \overline{0, n}$$

Далее будем работать уже с ортогональными разложениями номинального $\tilde{\varphi}_0(t)$ и текущего $\tilde{\varphi}(t)$ сигналов, т.е. фактически с коэффициентами разложения.

2. Найдём отклонения текущего сигнала от номинального, используя следующие метрики функционального анализа:

$$\rho(\tilde{\varphi}(t), \tilde{\varphi}_0(t)) = \sqrt{\int_a^b (\tilde{\varphi}(t) - \tilde{\varphi}_0(t))^2 dt}$$

$$\rho(\tilde{\varphi}(t), \tilde{\varphi}_0(t)) = \max_{a \leq t \leq b} \sum_{s=0}^k |\tilde{\varphi}(t)^{(s)} - \tilde{\varphi}_0(t)^{(s)}|$$

$$\cos \theta = \frac{(\tilde{\varphi}(t), \tilde{\varphi}_0(t))}{\|\tilde{\varphi}(t)\| \|\tilde{\varphi}_0(t)\|}, \quad (\tilde{\varphi}(t), \tilde{\varphi}_0(t)) = \int_a^b \tilde{\varphi}(t) \tilde{\varphi}_0(t) dt$$

Выводы

Причины целесообразности использования интегрального метода контроля сложных динамических систем:

- Использование ортогонального разложения по функциям Лагерра, которые обладают хорошими фильтрационными свойствами, позволяет

эффективно сглаживать помехи в выходном сигнале.

- Возможность выбора масштабного коэффициента позволяет настроить базис оптимальным образом под конкретный сигнал и получать точное разложение за минимальное время.

- Контроль отклонения текущего сигнала системы от номинального с помощью интегральных оценок позволяет построить эффективную реализацию алгоритма на ЭВМ и получать сведения о состоянии системы в реальном времени.

Проводимые исследования выполняются при финансовой поддержке РФФИ (номера проектов: 01-07-97060, 01-07-90317, 01-01-00894).

Литература

1. В.А.Бесекерский, Е.П.Попов Теория систем автоматического управления. // Наука. Москва, 1972. С.224-233.
2. Ф.Ф.Дедус, С.А.Махортых, М.Н.Устинин, А.Ф.Дедус Обобщённый спектрально-аналитический метод обработки информационных массивов. // Машиностроение. Москва, 1999. С.1-356.

Восстановление изображений с недостаточно определенным контуром

В.Л. Токарев, А.О. Гирлин, М.Ф. Садыков

(Тула)

Рассматривается задача, возникшая при построении трехмерного изображения объекта по множеству послойных двумерных изображений, полученных с ультразвукового диагностического прибора. Ультразвуковые приборы работают используя принцип отраженного сигнала. Ультразвуковые волны отражаются от целей-мишеней, которыми являются анатомические структуры внутренних органов. Все ультразвуковые приборы имеют датчик с пьезокристаллом, который посылает ультразвуковые волны в тело человека, затем воспринимает отраженные импульсы, преобразуя их в электрические сигналы которые через усилитель в итоге попадают на экран видеомонитора и регистратора.

В двумерном режиме пучок ультразвуковых волн распространяется от датчика и возвращается к нему в плоскости, т. е. имеет длину и ширину. Это позволяет ультразвуку проходить через структуры, находящиеся на разных глубинах и на одной и той же глубине. Эти структуры в зависимости от их акустической плотности регистрируются на экране в виде движущихся точек разной яркости. Помимо вертикального движения, свойственного одномерному режиму, в двумерном режиме точки движутся и по горизонтали, т. е. записывается боковое движение точек. На экране эти точки появляются с частотой более 30 раз в секунду. Все это создает условия для регистрации среза структур органа в реальном масштабе времени. Но

при этом послойные изображения имеют нечеткий характер, и получение необходимых для реализации трехмерного изображения их контуров представляет собой сложную задачу.

В докладе приводится вариант решения этой задачи, основанный на теории обеспечения рациональности решений [1]. По этому варианту получение послойного контура выполняется в два этапа. На первом этапе исходное изображение подвергается фильтрации, основанной на использовании модифицированного оператора Робертса. Наличие контура в исследуемом месте изображения определяется по максимуму нечеткой дисперсии, определяемой в окне фильтрации. При этом каждая оценка дисперсии сопровождается оценкой ее размытости (достоверности). При сравнительно большом показателе размытости решение о размещении точки контура не принимается. В результате линия контура в некоторых местах оказывается разорванной, и таком виде информация о контуре поступает на второй этап - анализ. На этапе анализа осуществляется связность фрагментов контура. Эта операция выполняется с привлечением множества моделей послойных контуров исследуемого объекта. Каждая модель представлена в виде двух векторов признаков, вычисленных в двух взаимно перпендикулярных плоскостях. Размерность векторов признаков определяется требуемой точностью получения трехмерного изображения, а вариативность векторов - задачей диагностики данной категории заболеваний. Вектор признаков, соответствующий неполному контуру, полученному на первом этапе, имеет пропуски по отдельным позициям вектора, и задача заключается в восстановлении недостающих признаков. Эта задача решается с помощью одной из моделей контура, для которой вычисляемая мера возможности оказывается максимальной. Мера возможности определяется на основе известных значений функций принадлежности выбираемой модели и полученного не полностью определенного контура:

$$\text{Poss}(\zeta_i | \zeta') = \bigvee_{\zeta_j \in Z_j} \mu_{\zeta_{ij}} \wedge \mu_{\zeta'_i}, \text{ где } \zeta_i - \text{признаки } j\text{-й модели,}$$

ζ'_i - признаки исследуемого контура.

Литература

1. Токарев В.Л. Основы теории обеспечения рациональности решений: Монография. - Тула: ТулГУ. 2000. – 118 с.

Анализ прогностических факторов риска в детской онкогематологии

И.Э. Том, О.В. Красько, М.П. Потанин, Т.А. Углова
(Минск)

Введение

Как известно, в общем виде задача распознавания или классификации заключается в нахождении комбинации наиболее значимых признаков (факторов) и последующем их использовании для классификации тех или иных объектов, явлений, процессов. В докладе рассматривается применение данного подхода в медицинских онкогематологических исследованиях.

Цель проводимых нами и нашими коллегами исследований – создание компьютерной информационно-аналитической системы, предназначенной для выявления комбинаций значимых прогностических факторов риска, их динамики в процессе лечения, для прогнозирования результативности лечения и выбора адекватной индуктивной терапии острых лейкозов у детей. В докладе кратко рассматриваются основные компоненты такой системы.

Архитектура информационной системы

Решение указанных выше задач возможно только с использованием современных информационных технологий проектирования баз данных, средств доступа к ним и методов анализа накапливаемой в них разнородной информации о пациентах. В настоящее время на смену наиболее распространенной информационной технологии работы с базами данных «клиент-сервер» приходит, так называемая, трехуровневая Web-технология или технология «тонкого» клиента. При такой технологии на клиентских станциях реализуются только диалоги пользователя, а бизнес-логика проверяется Web-сервером. Как правило для хранения данных используется SQL-сервер. За связи между данными и пользовательским интерфейсом отвечает Web-браузер с набором соответствующих скриптов, реализующих бизнес-логику. При этом клиентская станция, Web-сервер и SQL-сервер могут находиться на разных машинах или даже разнесены географически. В создаваемой нами системе мы используем преимущества Web-технологии и разрабатываем Web-приложения используя трехуровневую архитектуру информационных потоков «клиент – Web-сервер – сервер баз данных». На стороне Web-сервера для реализации пользовательского интерфейса нами используется ASP-технология, а ADO-компоненты применяются для доступа к серверу баз данных.

С точки зрения функционального подхода можно выделить следующие основные компоненты нашей системы, которые хорошо согласуются с выбранной информационной архитектурой, а именно: а) подсистема накопления клинико-лабораторной и эпидемиологической информации в

виде базы данных (БД) реляционного типа; b) Web-приложение как средство удаленного доступа к БД с целью ее наполнения, просмотра и редактирования; c) подсистема формирования сложных SQL-запросов к базе данных для последующего анализа извлеченной информации; d) подсистема многомерного статистического и интеллектуального анализа информации.

База данных

В качестве СУБД для проектирования базы данных была выбрана реляционная система MS SQL Server 2000, хорошо зарекомендовавшая себя при эксплуатации на платформах Windows NT/2000. Логическая структура базы данных соответствует разработанной регистрационной карте. Регистрационная карта, лежащая в основе базы медицинских данных, глубоко структурирована и содержит данные, сгруппированные по семи основным клинико-лабораторным и эпидемиологическим категориям: персональные данные, анамнез, преддиагностический период, сведения о лечении, клинические проявления, лабораторные данные, осложнения при проведении индукционной терапии и токсичность.

Подсистема анализа данных

Важнейшим компонентом нашей системы является подсистема многомерного статистического и интеллектуального анализа медицинских данных. Одной из актуальных задач в онкогематологии, является выбор адекватной терапии, что невозможно без прогнозирования ответа организма пациента на курс индукционной терапии острых лейкозов. Выявление 2-3 комбинаций наиболее значимых прогностических факторов (переменных) риска и оценка их прогностической значимости являются необходимым условием для решения задачи прогнозирования значений критерия отнесения больного к группе вышедших/не вышедших в ремиссию к окончанию терапии.

Для решения указанных выше основной и вспомогательных задач предлагается использовать комплекс методов и алгоритмов многомерного статистического и нейросетевого анализа данных. В частности для выделения комбинаций значимых переменных нами используется несколько различных алгоритмов многомерного статистического анализа, результаты которых проверяются на различных классифицирующих нейронных сетях. Критерием эффективности той или иной комбинации является вероятность безошибочной классификации наблюдений с ее использованием. Применение комплекса алгоритмов полезно для верификации получаемых результатов. Так в подсистеме реализован алгоритм пошагового отбора значимых переменных в задачах линейной регрессии, один из алгоритмов полного перебора для поиска подмножества значимых переменных в задачах квадратичной регрессии. Для этой же задачи реализованы два варианта алгоритма пошагового дискриминантного анализа на основе расстояния Махаланобиса.

В медицинских исследованиях часто число анализируемых независимых переменных сопоставимо с объемом генеральной выборки, поэтому применению указанных выше алгоритмов предшествует предобработка данных и использование ряда вспомогательных методов, в частности: однофакторный дисперсионный анализ, линейный и нелинейный варианты метода главных компонент в нейросетевой и статистической реализациях и ряд других, позволяющих редуцировать исходное множество переменных.

Полученные в результате математического решения данной задачи комбинации значимых прогностических факторов подвергаются сравнению и анализу медиками-клиницистами на предмет их медико-биологической корректности. Выбранная ими комбинация независимых переменных признается наиболее значимой, обладающей наибольшей прогностичностью и используется при решении следующей задачи — прогнозирования. Характерной особенностью выделенных комбинаций факторов является то, что они являются наилучшими по *совокупности* входящих в них переменных.

Как известно в основе задач прогнозирования лежат различные виды регрессионных моделей, поэтому из соображений изложенных ранее, для ее решения мы также используем совокупность взаимодополняющих статистических и нейросетевых моделей. В частности в стадии разработки или использования находятся следующие нейросетевые модели, используемые в нашей подсистеме анализа данных для решения задач отбора значимых признаков, классификации и прогнозирования: многослойный перцептрон (MLP) для задачи классификации (с тремя алгоритмами обучения и разной нормализацией); MLP–сеть для регрессионного анализа; MLP–сеть для линейного и нелинейного метода главных компонент; самоорганизующаяся сеть Кохонена (SOFM) для задачи кластеризации (два варианта топологии решетки и два типа обучаемой окрестности); SOFM для задачи классификации.

Заключение

Рассмотрены основные компоненты разрабатываемой системы анализа прогностических факторов риска для выбора адекватной индуктивной терапии острых лейкозов у детей. В создаваемой подсистеме анализа медицинских данных мы выступаем сторонниками совместного использования методов многомерного статистического и интеллектуального нейросетевого анализа данных. Реализуются различные типы нейронных сетей, которые в сочетании с методами многомерного статистического анализа, применяются для решения следующих задач: понижение размерности клинико-лабораторных данных, выявление комбинаций наиболее значимых прогностических факторов риска, классификация, прогнозирование исхода лечения и других. Мы ожидаем, что комплексное использование различных методологий анализа данных, их взаимное

дополнение и верификация, даст более корректные решения задач, стоящих перед современной онкогематологией.

Работа выполнена при поддержке гранта МНТЦ В-522.

Синтез полигауссовских алгоритмов обработки большеформатных полутоновых изображений

А.Т. Трофимов, В.А. Колядинцев, А.Е. Николаев

(Дубна, Великий Новгород)

Введение

Большеформатное полутоновое изображение $U(x,y)$ в виде яркостных отсчётов (пикселей) $U(x,y)$ с координатами $(x,y) \in \Omega$ всегда можно представить в виде совокупности сегментов, сосредоточенных в областях $(x^i, y^i) \in \Omega_i$ и $\bigcup_i \Omega_i \subseteq \Omega$; $i = 1 \dots I$. Разбиение на отдельные сегменты

предполагает выделение некоторых отсчётов $U_i = U_i(x,y) = U(x^i, y^i)$, однородных в смысле их принадлежности к случайному гауссовскому полю с соответствующими корреляциями R_i и математическим ожиданием $M_i = E[U_i]$.

При таком представлении обрабатываемого изображения статического или кадрового характера и при построчном считывании совокупность реализаций случайных полей, соответствующих сегментам Ω_i , будут характеризоваться полигауссовской плотностью распределения вероятностей [1].

Под полигауссовской подразумевается плотность вероятности $W[u]$, представляемая в виде конечной выпуклой комбинации гауссовских плотностей $N_i[u]$:

$$W[u] = \sum_{i=1}^I q_i N_i[u], \quad 0 \leq q_i \leq 1, \quad \sum_i q_i = 1 \quad (1)$$

В отмеченной работе доказывается, что в виде (1) с любой наперёд заданной точностью может быть представлена плотность распределения вероятностей произвольного случайного процесса (явления, поля, и т.п.).

Синтез алгоритмов обработки

Синтезированные полигауссовские алгоритмы подразумевают получение вектора достаточных статистик $T_i[u]$ и последующего их преобразования. В случае однородного гауссовского поля, характеризуемого корреляционными

матрицами по строке RS_i и по столбцу RC_i , и матричном представлении U_i , достаточные статистики определяются выражением

$$T_{i,k} = RC_i \cdot (U_k - M_i) \cdot RS_i \cdot (U_k - M_i)^T$$

При использовании различных критериев синтеза в структуре полигауссовских алгоритмов можно выделить определённую закономерность. В зависимости от решаемой задачи (фильтрация, идентификация, обнаружение, оценка, координат наблюдаемого объекта и т.д.) и используемого соответствующего оператора преобразования $P_i[u]$, полученного для случая гауссовского обрабатываемого изображения, полигауссовский алгоритм имеет вид:

$$P(u) = \sum_{i=1}^I P[u]_i \cdot \sigma_i[T_{i,k}]$$

где $\sigma_i[T_{i,k}]$ - по своему смыслу характеризует апостериорную плотность вероятности i -ой гауссовской компоненты.

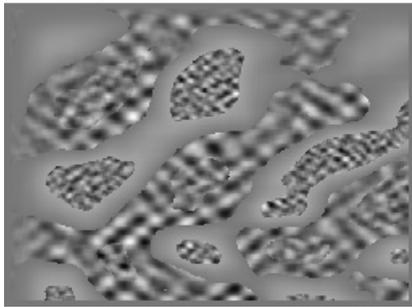


Рис. 1. Исходное изображение.

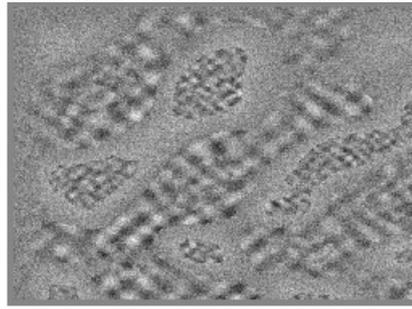


Рис. 2. Смесь исходного изображения с шумом.

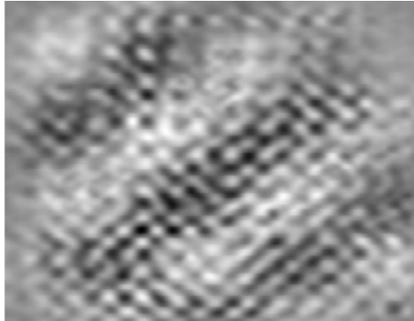


Рис.3. Результат обработки (общий корреляционный оператор).

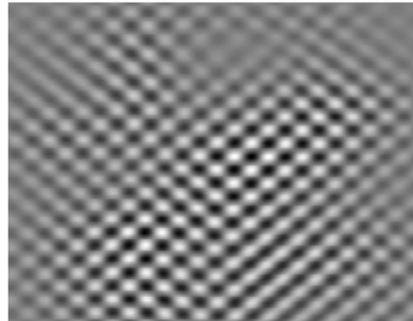


Рис.4. Результат обработки (первый корреляционный оператор).

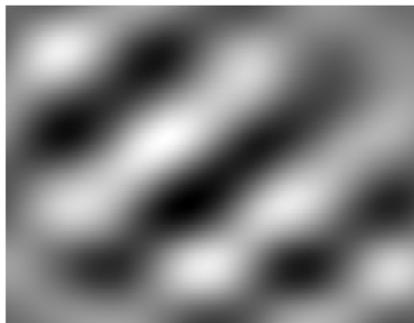


Рис.5. Результат обработки (второй корреляционный оператор).

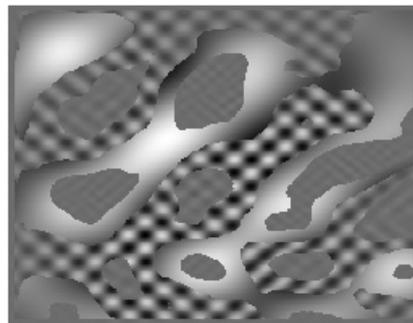


Рис.6. Результат полигауссовской обработки.

Для наглядности эффективности применения полигауссовских алгоритмов на рисунках представлены последовательно: исходное изображение на рис.1, смесь исходного изображения с шумом на рис.2, результат корреляционной обработки для каждого отдельного корреляционного оператора (рис.3-5) и результат фильтрации с применением полигауссовского алгоритма на рис.6. Эффективность последнего, как можно заметить по рисункам является достаточно очевидной.

Заключение

Применение полигауссовских алгоритмов позволяют существенно повысить качество обработки большеформатных изображений. Следует отметить так же такие свойства этих алгоритмов, как асимптотическую оптимальность и робастность.

Литература

1. Трофимов А.Т. Полигауссовские вероятностные модели и синтез информационных систем / НовГУ им. Ярослава Мудрого. — Великий Новгород, 2002.— 183с.

Функциональная модель интеллектуального электронного пособия

Ш.Е. Туляганов, О.Ж. Бобомуродов, М.Х. Худайбердиев
(Ташкент)

Интеллектуальное электронное пособие (ИЭП) является интеллектуальным электронным учебно-методическим пособием (ИЭУМП), имеющим следующие функционально – логические и дидактические возможности:

представление максимально полного материала по изучаемой дисциплине;

демонстрация материала мультимедиа – средствами;

тестирование и диагностика обучаемого с целью оценки уровня глубин усвоения им текущего материала и степени приобретения навыков и умений;

тренинг и диагностика методами распознавания обучаемого по приобретению и закреплению навыков и умений, сопровождаемые постоянным контролем и оценкой каждого из этапов тренинга;

формирование учебно-методического материала для изучения очередной темы (раздела), объём и содержание, которые система определяет в соответствии с полученной оценкой уровня и глубины усвоения теоретического материала, а также практических навыков и умений по предыдущим разделам дисциплины;

организация электронного пособия по гипертекстовой структуре, что позволяет осуществлять построение функциональных, содержательных и логических взаимосвязей понятий, имён, отношений, явлений и процессов, изучаемых в данном разделе, с соответствующими им объектами, которые рассматривались и изучались предыдущих разделах, а также будут изучаться в последующих разделах;

разъяснение обучаемому, при необходимости, почему и на основании каких понятий, отношений законов, методов, теорем, явлений и закономерностей получают рассматриваемые решения и формируются новые понятия, отношения, взаимосвязи и выводы.

ИЭП можно представить моделью:

$$E = \langle A, A_i, H_i, B, Q \rangle .$$

Здесь А – база знаний (БЗ), A_i - вероятность обращений, H_i – система помощи, В – критерия оценки, Q – взаимосвязь между элементами. В свою очередь БЗ состоит из нескольких элементов:

$$\psi_i = A_i + H_i$$

то есть:

$$A = \sum_{i=1}^n \psi_i + U$$

здесь U – обобщение знаний по предмету [1].

С целью отношения реализации этих возможностей ИЭП в интеллектуальные системы обучения (ИСО) представляются в виде информационных моделей двух типов: модели данных и модели знаний (БД) [2,3].

Модель знаний (МЗ) полного текста ИЭП представляется в виде ориентированного графа

$$\Gamma = I = \{ A_i, G_{ik} \},$$

где A_i – множество вершин, отражающие номера структурно-содержательных частей пособия (частей, разделов, глав, параграфов, подпараграфов и т.д.); G_{ik} – множество дуг, характеризующих содержательно-логические взаимосвязи между i -й и k -вершинами.

В свою очередь граф полного текста ИЭП состоит из множества подграфов, т.е.

$$I = I_{ji_j},$$

где I_{ji_j} – подграфы, отражающие модели соответствующих структура содержательных частей ИЭП, т.е. i_j – раздела, j – уровня. Подразделы I_{ji_j} являются частными графами, вложенными в полный граф модели знаний пособия.

В базе данных ИЭП, как правило, представляется в виде реляционной модели

$$D = \{ D_{1i_1} (D_{2i_2} (\dots (D_{ji_j} (\dots (D_{nm}) \dots)) \dots) \dots) \},$$

где D_{ji_j} – полнотекстовая модель i_j – раздела j – го уровня ИЭП (например, i_j - подграф, j - глава).

Между полными моделями данных D и знаний I , а также между их фрагментами обеспечивается взаимно однозначное отображение

$$\begin{aligned} D &\Leftrightarrow I \\ D_{ji_j} &\Leftrightarrow I_{ji_j} \end{aligned}$$

Выводы

Интеллектуальные электронные учебники, пособия и методические материалы, динамически формируемых в соответствии с уровнем подготовленности обучаемого, позволяют достаточно эффективно изучать

выбранные дисциплины самостоятельно в системах дистанционного образования.

Литература

1. Бекмуратов Т.Ф., Бобомуродов О.Ж. Электрон укув кулланмаларни куриш усули.//Таълим муаммолари, №3,2001г.
2. Петрушин В.А. Интеллектуальные обучающие системы: архитектура и методы реализации.// Техническая кибернетика, №2,1993г.
3. Усачев Ю.Э. Проектирование интеллектуального учебника.// Дистанционное обучение,3'2000г.
4. Бекмуратов Т.Ф. Управление в условиях неопределённости.// Вопросы кибернетики, Ташкент №162, 2001г.
5. Растринин Л.А., Эренштен М.Х. Адаптивное обучение с моделью обучаемого. // Рига: Зинатне, 1988. – 160 с.

Измерение наноструктур методом морфологического анализа изображений

Д.М. Устинин, А.И. Чуличков

(Москва)

В технологии микроэлектроники и других областях возникают проблемы измерения параметров наноструктур, полученных искусственно или существующих в природе. Растровые и просвечивающие электронные микроскопы являются основными инструментами, используемыми для этой цели. Однако, для получения информации о параметрах структур, таких как средний размер, распределение по размерам, расстояния между структурами, плотность их размещения и т.д., требуется применять те или иные методы анализа изображений. Если геометрическая форма измеряемых объектов известна, очень эффективными оказываются методы морфологического анализа изображений [1].

В данной работе методами морфологического анализа решалась задача определения размеров наночастиц в форме плоского диска по изображениям в растровом электронном микроскопе. Используя моделирование методом Монте-Карло, строилась идеальное изображение частиц в РЭМ, а также модель, описывающая возможные отклонения измеряемых изображений от идеальных. Затем была построена форма изображения наночастицы как множество всех возможных в данных условиях изображений. Это множество зависит от параметров, описывающих размеры и положение частиц. Если построить проекцию изображения, полученного в микроскопе, на это множество, и затем варьировать параметры положения и размера частиц, то проекция будет максимальной, когда параметры будут соответствовать частицам на исследуемом изображении. Таким способом были определены размеры и положение частиц.

Литература

1. Грачев Е.А., Устинин Д.М., Чуличков А.И. Линейные измерения в растровой электронной микроскопии на основе методов морфологического анализа изображений, Математическое моделирование, 2003 г., №3

Об одной алгоритмической схеме решения задачи распознавания лиц

Ш.Х. Фазылов, М.Т. Тухтасинов

(Ташкент)

Автоматическое распознавание лиц - одно из перспективных направлений обработки изображений и широко используемое в системах наблюдения, контроля доступа и криминалистике.

В докладе рассмотрены отдельные методы и алгоритмы идентификации лиц на изображении, а также экспериментальные результаты, полученные в процессе использования алгоритмической схемы, базирующейся на реализации следующих четырех этапов обработки изображений: автоматическая локализация лица на изображении; преобразование исходного изображения лица в начальное представление (предобработка и вычисление главных компонент); выделение ключевых характеристик (первых нескольких главных компонент преобразования) и последующая классификация на основе какой-либо метрики. Реализация этих этапов осуществляется следующим образом.

Предварительно выполняется выравнивание гистограммы яркости исходного изображения, при котором улучшается контрастность. Далее для устойчивого выделения лица на изображении применяется комбинация нескольких алгоритмов - извлечение движущихся объектов из последовательности видео-кадров с помощью временной свертки [1] и метод сегментации по цвету кожи лица. Для сегментации цветное изображение формата RGB отображается в YUV- и YIQ-пространства [2], а также в Lab-пространство [1]. Анализируя гистограмму яркостей в полученных пространствах можно эффективно выделять области лица. Пример выполнения сегментации и последующего выделения границ лица оператором Собеля представлен на рисунках 1 и 2.



Рис. 1. Сегментация цветного изображения



Рис. 2. Выделение границ объекта оператором Собеля

Отметим, что путем анализа 8-связности областей сегментации определяются такие объекты лица, как брови, глаза и губы. Полученная информация используется для геометрической нормализации объекта сравнения (масштаб, положение, ориентация, отсечение фона).

После выделения лица на изображении и соответствующей нормализации к приведенным к единому масштабу и отцентрированным полутоновым (8-битовым) изображениям применен метод главных компонент (или преобразования Карунена-Лоэва) в соответствии с [3] и [4].

Пример собственных лиц и восстановленного методом главных компонент изображения представлен на рисунках 3-5.



Рис. 3. Пример собственных лиц



Рис. 4. Исходное изображение



Рис. 5. Реконструированное изображение

Собственно процесс распознавания лица заключается в сравнении главных компонент неизвестного изображения с компонентами всех остальных изображений. В простейшем случае возможно применение евклидова расстояния или метрики Махаланобиса.

Литература

1. Sun Q.B., Lam C.P., Wu J.K. "A Practical Automatic Face Recognition System", Face Recognition from Theory to Application, NATO ASI Series, v. 163, 1998.
2. Mazumdar D., Dutta S., Mitra S. "Automatic feature detection of a face and recovery of its pose", communicated to Journal of IETE.
3. Turk M., Pentland A. "Face Recognition Using Eigenfaces", Proceedings Computer Vision and Pattern Recognition, pp. 586-591, 1991.

4. Sirovich L., Kirby M., "Low-dimensional procedure for the characterization of human faces", Journal of the Optical Society of America A, v. 4, № 3, pp. 519- 524, 1987.

Методы предварительной обработки изображений на основе Трасе-преобразования

Н.Г. Федотов, Т.В. Никифорова

(Пенза)

Методы распознавания на основе стохастической геометрии, включающие Трасе-преобразования изображений, являются удобным инструментом для получения признаков исследуемых объектов [1]. Характерной особенностью формируемых признаков является их структура в виде композиции трех функционалов. Такая структура обеспечивает возможность получения большого числа признаков, простоту их генерации, и, что особенно ценно, возможность формировать признаки, обладающие определенными свойствами. В частности, варьируя функционалы, можно добиться описания, инвариантного к сдвигам, вращениям и линейным деформациям изображений объектов или, напротив, чувствительного к ним [1, 2].

Для получения признаков изображение, расположенное на входной сетчатке системы распознавания, сканируется решеткой параллельных прямых с расстоянием $\Delta\rho$ между линиями. Взаимное положение исследуемого изображения F и каждой сканирующей линии $l(\rho, \theta)$ характеризуют числом g , вычисляемым по некоторому правилу T : $g = T(F \cap l(\rho, \theta))$. В качестве указанной характеристики может выступать, например, число пересечений прямой с изображением, длина части прямой, лежащая внутри изображения, или свойства окрестности такого сечения. Отображение T называют функционалом. Функционал T связан с естественной координатой t сканирующей линии.

Далее сканирование производится для нового значения угла, получившего дискретное приращение $\Delta\theta$, решеткой линий с тем же шагом $\Delta\rho$.

Результат вычислений T функционала зависит от нормальных координат прямой ρ и θ , поэтому получаемое в результате сканирования множество чисел $g = T(F \cap l(\rho, \theta))$ есть некоторое преобразование изображения, которое называют Трасе-преобразованием (Трасе от английского слова «след»). При численном анализе Трасе-преобразование принято представлять в виде матрицы или Трасе-матрицы, у которой ось $O\theta$ направлена горизонтально, а ось $O\rho$ – вертикально. Элемент Трасе-матрицы, стоящий на пересечении i -й строки и j -го столбца есть: $g_{ij} = T(F \cap l(\rho_i, \theta_j))$, т. е. каждый столбец матрицы содержит значения, вычисляемые по всем прямым при одинаковом значении

угла θ . Если прямая l не пересекает изображение, то $T(F \cap l(\rho, \theta))$ полагают равным заданному числу (например, нулю).

После заполнения Тгасе-матрицы продолжается формирование триплетного признака. С помощью диаметрального функционала P осуществляется постолбцовая компрессия Тгасе-матрицы. Результатом этой обработки является π (2π)-периодическая функция. Воздействуя на нее круговым функционалом Θ , получаем некоторое число – признак изображения $\Pi(F) = \Theta \cdot P \cdot T(F \cap l(\rho, \theta))$.

Теоретические исследования и применение методов стохастической геометрии к решению практических задач позволили установить новую особенность этого математического аппарата – возможность осуществления предварительной обработки изображений (фильтрации, полигональной аппроксимации, инверсии изображений).

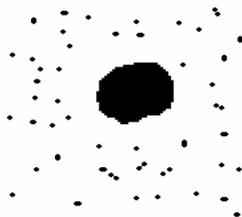
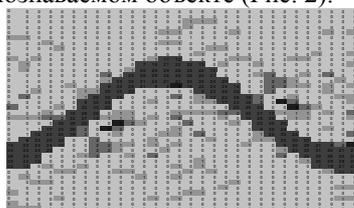


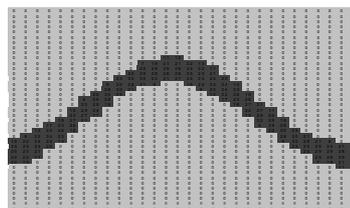
Рис. 1. Исследуемое изображение.

В случае, когда для анализа предъявляется изображение, содержащее шумовые элементы (Рис. 1), нелинейная фильтрация реализуется следующим образом.

При осуществлении сканирования T функционал определим как вычисление длины части прямой, лежащей внутри изображения. Поскольку размер анализируемого объекта много больше размера шумовых точек, то длины отрезков, высекаемых объектом и шумовыми точками, различаются на порядки. Определяя порог длин отрезков, учитываемых при построении Тгасе-матрицы, получаем возможность обрабатывать информацию только о распознаваемом объекте (Рис. 2).



а



б

Рис. 2. Трасе-матрицы исследуемого изображения, соответствующие различным T функционалам:

а – подсчет длин отрезков, б – подсчет длин отрезков, превышающих заданный порог

Примером T функционала, задаваемого для фильтрации изображений, является следующий: $\sum_{i=1}^N t_i - t_{i-1}$, если $(t_i - t_{i-1}) > 3$, где t_i – координата точки знакоперемены на сканирующей прямой.

Фильтрацию изображения можно усилить, если использовать фильтрующие свойства и других функционалов трехзвенной структуры.

Полигональная аппроксимация осуществляется с целью уменьшения избыточности информации в случае, когда для распознавания предъявляются сложные изображения (Рис. 3).



Рис.3. Исследуемое изображение.

Для получения информации только о внутренней окружности исследуемого изображения применяем следующий T функционал:

$$a_{ij} = \begin{cases} 0, & \text{если } a_{ij} = 0, \\ 10 \lceil \lg a_{ij} \rceil, & \text{если } a_{ij} > 0, \end{cases} \quad (1)$$

где a_{ij} – число отрезков, высекаемых изображением на сканирующей прямой, $i = \overline{1, n}$, $j = \overline{1, k}$, n – число сканирующих линий, k – число поворотов решетки.

В заключении следует подчеркнуть, что используя методы стохастической геометрии можно в единой технике осуществлять нелинейную фильтрацию изображений и формировать признаки распознавания. Это позволяет повысить быстродействие распознающих систем, поскольку предварительная обработка изображений и формирование признаков происходит в едином такте работы сканирующей системы.

Литература

1. Федотов Н.Г. Методы стохастической геометрии в распознавании образов. – М.: Радио и связь, 1990. – 142 с.

2. Федотов Н.Г., Кадыров А.А. Новые методы формирования признаков распознавания образов с позиций стохастической геометрии //Автометрия. – 1996. – №3. – С. 88 – 92.

Кватернионный анализ изображений

Я.А. Фурман

(Йошкар-Ола)

Значительное количество актуальных научно-технических задач сводится к обработке информации, получаемой от компактно расположенных на плоскости или в пространстве групп точечных объектов (ГТО). Примерами ГТО служат изображения микробиологических объектов, изображения звезд в пределах машинного кадра астродатчика летательного аппарата, изображения на индикаторах радио- и гидролокационных станции. К обработке ГТО сводятся задачи, связанные со сплошными изображениями. Для этого границы (контуры) плоских или трехмерных изображений представляются набором точек, являющихся корректно взятыми отсчетами этих контуров.

При обработке сигналов, адекватных ГТО, применяются методы теории сигналов - спектральный и корреляционный анализ, различные виды фильтров, в первую очередь, согласованная. Сами сигналы представляют комплекснозначные векторы, трактуемые как дискретно заданные контуры. Данное обстоятельство ограничивает применение упомянутых методов случаев плоских изображений.

В докладе рассматриваются основные положения и результаты теории кватернионных сигналов (КТС) к заданию и обработке пространственно заданных ГТО. Методология данной теории базируется на распространении основных результатов анализа заданных на плоскости ГТО на подобные изображения, расположенные в трехмерном пространстве.

Сложности перехода в третье измерение связаны не только со значительным ростом количества обрабатываемых пикселей, но, в первую очередь, с отсутствием удобных теоретических подходов к обработке трехмерных форм. Такие подходы могут быть реализованы на базе алгебры кватернионов.

Теория гиперкомплексных чисел существует давно, но ее применение для практических целей крайне ограничено по сравнению с другими математическими конструкциями, например, комплексными числами. Основная сложность получения КТС вызвана отсутствием меры схожести таких сигналов, например в виде их скалярного произведения. Наличие такой меры схожести дает возможность применить методы теории сигналов к кватернионным моделям. Скалярное произведение рассматриваемых в качестве векторов сигналов позволяет задать ортогональную систему отсчета, ввести понятие спектра, АКФ и ВКФ, синтезировать согласованные

фильтры, являющиеся базовыми звеньями в устройствах оптимального и квазиоптимального обнаружения, распознавания и оценки параметров сигнала.

При рассмотрении вопросов, связанных с созданием теории кватернионных сигналов, была использована тесная связь кватернионов с комплексными числами, лежащими, в свою очередь, в основе контурного анализа. Были получены i, j, k - комплексные формы кватернионов, позволяющие представить кватернионный сигнал в виде пучка “комплексных” векторов. В результате скалярное произведение комплекснозначных векторов обобщено на случай скалярного произведения кватернионных сигналов. Дальнейшие результаты, связанные с их спектральным анализом и сопряженно-согласованной фильтрацией, получались по известной схеме с учетом некоммутативности операции умножения кватернионов.

В методическом плане заслуживают внимание введенные элементарные кватернионные сигналы. Семейство этих сигналов образует ортонормированный базис, т.е. скалярное произведение таких сигналов разных порядков равно нулю, а одинаковых порядков – единице. Отметим, что обычный декартов базис применительно к кватернионам уже не обладает таким свойством ортонормированности. Поэтому только в базисе из полного семейства элементарных кватернионных сигналов возможно разложение произвольных кватернионных сигналов. В результате такой сигнал представляется линейной комбинацией элементарных сигналов, весами в которой служат компоненты спектра сигнала.

Другим важным моментом является введение АКФ и ВКФ кватернионных сигналов как семейства значений их скалярных произведений при вариации параметра одного из сигналов. Это позволило получить согласованный фильтр, т.е. фильтр, импульсная характеристика которого определяется эталонным сигналом. При фильтрации другого кватернионного сигнала выходной сигнал фильтра служит мерой схожести входного и эталонного сигналов. Поэтому набор согласованных кватернионных фильтров является основой построения устройства распознавания кватернионных сигналов.

Еще одним важным моментом является проблема потенциальной помехоустойчивости комплексных и кватернионных сигналов, рассмотренная в данной работе применительно к решению задачи распознавания. Для достаточно общих условий, при которых она решается, синтезированы алфавиты комплексных и кватернионных сигналов, обеспечивающие предельно достижимые вероятности правильного распознавания. Данные условия заключаются в выборе аддитивной модели зашумленного сигнала, нормального закона распределения вероятностей широкополосного шума и использовании для принятия решения о классе

критерия минимального расстояния между векторами распознаваемого и эталонных сигналов. Синтезированные алфавиты состоят из симплексных сигналов. Векторы, задающие их, разнесены между собой на максимально возможные расстояния по сравнению с любыми другими сигналами одинаковой энергии.

Работа выполнена при финансовой поддержке РФФИ, проекты №01-01-00298, № 03-01-06550.

Литература

1. Введение в контурный анализ и его приложения к обработке изображений и сигналов/ Я.А. Фурман, А.В. Кревецкий, А.К. Передреев, А.А. Роженцов, Р.Г. Хафизов, И.Л. Егошина, А.Н. Леухин. Под общей редакцией Я.А. Фурмана. – М.: Физматлит, 2002.
2. Furman Ya. A. Processing of Quaternion Signals Specifying Spatially Located Group Point Objects// Pattern Recognition and Image Analysis, Vol. 12. № 2, 2002. pp. 175-193.
3. Фурман Я.А., Хафизов Д.Г. Распознавание групповых точечных объектов в трехмерном пространстве. / Автометрия, 2003, №1. – С.3-18.

Распознавание кватернионных сигналов на основе их представления в собственной системе отсчета

Р.Г. Хафизов
(Йошкар-Ола)

Неинвариантность модуля скалярного произведения кватернионных сигналов $\mathbf{Q} = \{q(n)\}_{0,s-1}$ (КТС) к величине угла их взаимного поворота в значительной степени по сравнению со случаем комплекснозначных сигналов усложняет процедуру распознавания [1,2]. Как правило для принятия решения о классе зашумленного и преобразованного КТС необходимо выполнить дополнительные операции: либо найти оценку угла его поворота относительно эталонного сигнала своего класса и затем скорректировать угловое рассогласование, либо выполнить близкую по содержанию операцию совмещения двух КТС. При наличии шумов каждая из этих операций сопровождается неизбежной ошибкой, что в конечном счете, снижает вероятность правильного распознавания сигнала и значительно увеличивает время принятия решения по сравнению со случаем отсутствия углового рассогласования между распознаваемым и эталонным КТС [2].

В связи с этим значительный интерес представляют подходы к распознаванию КТС, свободные от дополнительных по сравнению с комплекснозначными сигналами операций. Один из таких подходов базируется на задании кватернионного сигнала в собственной системе

отсчета. В этом случае все амплитудные и фазовые данные для текущего кватерниона задаются относительно кватерниона с предыдущим номером либо по отношению к интегральной характеристике всего КТС. При обработке кватернионных сигналов, заданных в собственной системе отсчета, соотношение между номерами соответствующих кватернионов должно быть задано.

В докладе рассматривается один из подходов к заданию КТС в собственной системе отсчета. Такое представление было получено при использовании свойства конформности (сохранения углов между кватернионами) операции вращения векторного КТС, т.е. угол между двумя кватернионами $q(n)$ и $q(n+1)$, входящими в состав КТС \mathbf{Q} сохраняется при любых вращениях КТС \mathbf{Q} в пространстве.

Упорядоченная последовательность $\Theta = \{\cos \theta(n)\}_{0,s-1}$, задает обладающую свойством инвариантности к вращениям угловую структуру КТС в собственной системе отсчета

$$\Theta = \text{const} \quad \text{для любого КТС вида } b\mathbf{Q}b^{-1}.$$

Модульная структура КТС задается последовательностью

$$\Omega = \left\{ \frac{|q(n)|}{\|\mathbf{Q}\|} \right\}_{0,s-1}.$$

Эта структура инвариантна к изменению масштаба сигнала:

$$\Omega = \text{const} \quad \text{для любого КТС вида } h\Omega,$$

где $h \neq 0$ – произвольное вещественное число.

Последовательности Θ и Ω являются структурными признаками образа, задаваемого кватернионным сигналом. Они не меняются при вращении и масштабировании КТС, а при сдвиге на величину d номера начального кватерниона происходит аналогичный циклический сдвиг элементов в последовательностях Θ и Ω .

На основе последовательностей Θ и Ω создается последовательность $\Phi = \{\varphi(n)\}_{0,s-1}$, объединяющую содержащуюся в них информацию о КТС \mathbf{Q} :

$$\varphi(n) = \frac{|q(n)|}{\|\mathbf{Q}\|} \cos \theta(n),$$

Последовательность Φ в векторном виде будем рассматривать в качестве сигнала, имеющего ту же размерность, что и КТС Q и отражающего его структуру.

Структурные представления КТС являются информативными признаками формы сигналов. Они инвариантны к преобразованиям вращения и масштабирования. Сдвиг номера начального кватерниона в сигнале меняет лишь порядок компонент векторов этих представлений. Поэтому результаты распознавания зашумленных КТС по их структурным представлениям не будут зависеть от вращения, масштабирования зашумленного КТС и сдвига номера его начального кватерниона.

Литература

1. Введение в контурный анализ и его приложение к обработке изображений и сигналов// Под ред. Я.А. Фурмана.– М.: Физматлит, 2002.
2. Фурман Я.А., Хафизов Д.Г. Распознавание групповых точечных объектов в трехмерном пространстве// Автометрия, 2003, №1. – С.3-18.

Имитатор сетчатки глаза для визуальной коммуникации

Г.В. Цепков, А.В. Лефтеров

(Киев)

Прием-передача речевых сообщений целесообразно лишь при отсутствии языкового барьера. В противном случае вместо слуховой коммуникации используется визуальная: мимика, жесты, рисуночное письмо и т.п. Под рисуночным письмом (пазиграфией) подразумевается система условно символического представления образов окружающего мира и его взаимосвязей, позволяющая осуществлять визуальный обмен информацией между участниками коммуникационного процесса.

Обучение человека пазиграфии значительно легче, чем освоение нового «фонетического» языка, такого как эсперанто и ему подобных. Если основу условной символики представляет ограниченный набор унифицированных пиктограмм (построенных из базовых графо-семантических элементов по определенным смыслообразующим правилам), то появляется возможность с помощью средств вычислительной техники реализовать систему для визуальной коммуникации.

Но создание подобной электронной коммуникативной среды вызывает ряд технических и алгоритмических проблем, связанных с вводом («восприятием») и интерпретацией («узнаванием») пазиграмм. В известных проектах «всемирного письма» рассмотрению этих проблем должное внимание не уделяется. Между тем, вид и количество элементов, образующих пазиграмму, существенно влияют на реализацию системы ввода в ЭВМ изображений и степень сложности алгоритмов их анализа.

В докладе рассматриваются вопросы модификации элементов пазиграмм,

предложенных Ж. Эффелем (один из немногих проектов конца 20 века, опирающихся на графический базис в процессе лингвопроектирования), а также особенности программно-технической реализации системы для обработки пазиграмм и базовых графо-семантических элементов иероглифов. Описывается организация и функционирование упрощённой модели сетчатки глаза, которая ориентирована на прием и предварительную обработку модифицированных пазиграмм с помощью ЭВМ.

Основу системы составляет программно-информационная модель - имитатор сетчатки, в котором использованы некоторые известные принципы организации рецепторных элементов глаза и их коммуникативные механизмы. Имитатор, подобно сетчатке, многослойный. Каждый слой имитирует определенный этап обработки глазом видимого образа. Цельность и последовательность имитации процесса обработки образа поддерживается управляющей компонентой системы.

Начальный слой «сетчатки» представляет собой прямоугольную матрицу, содержащую $n * m$ светочувствительных $\{p_{i,j}\}$ элементов типа «off», на которые проецируется изображение (PAZ). На начальном этапе определяется центр площади «S» изображения (центрирование).

Метод центрирования основан на поиске сбалансированного положения PAZ относительно двух взаимно перпендикулярных осей, каждая из которых делит матрицу на две равные части. Для сбалансирования «S» относительно горизонтальной оси $\{p_{i,j}\}$ элементам, которые срабатывают в верхней части матрицы, задаются веса +1, а тем которые сработали в нижней части -1; веса незатененных элементов нулевые, т.е. вес $\{a_{i,j}\}$ определяется условием:

$$a_{i,j} = \begin{cases} 1, p_{i,j} \in P, I \in [1, m/2] \\ -1, p_{i,j} \in P, I \in [1, m/2] \\ 0, p_{i,j} \in P \end{cases} \quad (1)$$

где i - номер строки ($i = 1, 2, \dots, n$); j - номер столбца ($j = 1, \dots, m$).

Балансировка производится сравнением суммарных весов сработавших верхних и нижних элементов матрицы и смещением ее по вертикали до того момента, когда суммарные веса сравниваются.

При балансировке «S» относительно вертикальной оси правило задания весов $\{a_{i,j}\}$ несколько изменяется; в (1) символ « i » всюду (кроме индекса) заменяется на « j », а « m » заменяется на « n ». Балансировочные операции осуществляются подобно вышеописанным.

После центрирования производится анализ PAZ. Веса элементов мат-

рицы теперь изменяются по правилу:

$$a_{i,j} = a_{1,1} + q(i-1) + (j-1), \quad (2)$$

q, k - приращение веса элемента по вертикали и по горизонтали, соответственно.

Такая организация « q », « k » определяет значения приращений « l », « $г$ » по диагоналям матрицы (наклон вправо $r = q + k$; влево $l = q - k$). Чтобы величины « $a_{1,1}$ », « k », « l », « $г$ » не совпадали следует принять: $a_{1,1} > l; q > k$.

Теперь при затемненные PAZ элементы матрицы включаются со своим весом и начинается анализ, где имитируются латеральное торможение и послонная обработка пазиграммы. Латеральные тормозные связи имитирует вычитание веса предыдущего элемента из веса последующего. Каждый слой в соответствии с организацией связей между $\{p_{i,j}\}$ выделяет определенные признаки PAZ. В "слое", имитирующем горизонтальные тормозные связи между $\{p_{i,j}\}$, образуется последовательность элементов, имеющих вес:

$$b_{i,j} = a_{i,j+1} - a_{i,j}, \quad (3)$$

что указывает на наличие в PAZ горизонтальных отрезков. Координаты отрезков на матрице указываются $\{a_{i,j}\}$ крайних элементов (сработавших, но не подвергшихся торможению), а длина - количеством $\{b_{i,j}\}$.

После обработки новые весовые данные элементов поступают в "слой", где имитируется работа латеральных связей по вертикали. В результате веса изменяются в соответствии с формулой:

$$c_{i,j} = b_{i+1,j} - b_{i,j} \quad (4)$$

При этом выявляется наличие и число вертикальных отрезков в PAZ, их координаты, длина, а заодно достигается контрастирование горизонталей.

Последовательно имитируя работу тормозных связей между $\{p_{i,j}\}$ по диагонали вправо и влево, получаем новые веса элементов, соответственно:

$$d_{i,j} = c_{i+1,j+1} - c_{i,j}, \quad (5)$$

$$e_{i,j} = d_{i+1,j-1} - d_{i,j}. \quad (6)$$

В результате описанных действий в последнем слое "сетчатки" образуются цепочки возбужденных элементов (характеристические признаки изображения), часть которых имеет веса « q », « k », « l », « $г$ ». Таким образом кодируется наличие в изображении горизонталей, вертикалей,

наклонов. Элементы с иными весами указывают на координаты отрезков, изломы, пересечения.

Набор этих признаков достаточен для распознавания стилизованных РАЗ. Стилизация, в основном, сводится к тому, чтобы наклоны отрезков в рисунке составляли 45° . Если кодируются и длины отрезков, то обеспечивается также возможность синтеза рисунка.

Такую «сетчатку», как не трудно заметить, можно использовать в системах для обработки и анализа не только пазиграмм, но также других общеизвестных стилизованных символов, относящихся к лингвистике, математике, физике, химии и др.

Круг возможных применений существенно расширяется, если помимо выполняемой имитатором предварительной обработки изображений используются программные и/или технические средства, ориентированные на сокращение избыточности видеоданных, защиту факсимильной информации и т.п.

Алгоритм текстурной сегментации с помощью раскрашенной карты Кохонена и фильтров Габора

Д.А. Цымбал, Г.М. Емельянов, Д.В. Разумов
(Великий Новгород)

Процесс текстурной сегментации изображения, представленный на рис.1, осуществляется следующим образом [1].

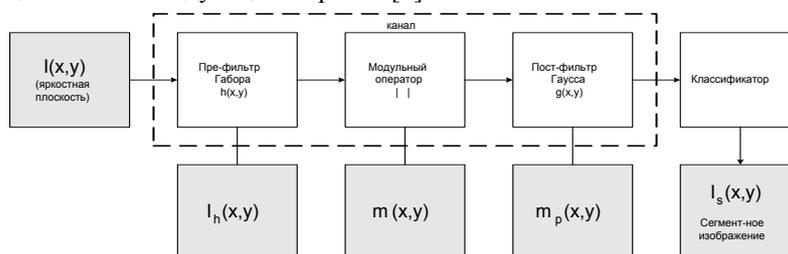


Рис. 1. Схема одноканальной системы текстурной сегментации изображения.

Изображение $I(x,y)$ (переведенное из RGB в HSB систему), состоящее из N различных текстур, обрабатывается полосовым префильтром Габора, имеющим импульсную характеристику

$$h(x, y) = g(x, y)e^{-j2\pi(Ux+Vy)} = \frac{1}{2\pi\sigma_g^2} e^{-\frac{(x^2+y^2)}{2\pi\sigma_g^2}} e^{-j2\pi(Ux+Vy)}$$

Параметры (U, V, σ_g) определяют префильтр Габора. Параметры (U, V) определяют центральную частоту префильтра, а σ_g - полосу пропускания.

Изображение $I_h(x,y)$ на выходе префилтра Габора представляет собой свертку импульсной характеристики префилтра и исходного изображения

$$I_h(x,y) = I(x,y) * h(x,y)$$

где * обозначает операцию двумерной свертки. Затем вычисляется модуль изображения $m(x,y)$ по формуле

$$m(x,y) = |I(x,y) * h(x,y)|.$$

После этого, изображение $m(x,y)$ подвергается постфильтрации фильтром Гаусса

$$m_p(x,y) = m(x,y) * g(x,y) = m(x,y) * \frac{1}{2\pi\sigma_p^2} e^{-\frac{(x^2+y^2)}{2\pi\sigma_p^2}}$$

где параметр σ_p определяет постфильтр Гаусса. Далее, сегментация изображения осуществляется классификатором на основе самоорганизующейся карты Кохонена.

Параметры фильтров (U, V, σ_g, σ_p) выбираются на основе метода, рассмотренного в работе [2,3], так чтобы ошибка сегментации была минимальна.

Классификация и сегментация текстурного изображения раскрашенной картой Кохонена

Применение нейронных сетей для решения задач классификации позволяет избежать сложных и громоздких расчетов при оперировании большими объемами многомерных данных. Самоорганизующаяся карта Кохонена производит классификацию входных векторов. Карта представляет собой пространство невысокой размерности, что позволяет легко визуализировать результат. Более того, когда размещение нейронов закончено карта может быть отображена (раскрашена). Это свойство карты позволяет произвести не только классификацию входных данных из пространства признаков, но и в рассматриваемом случае выполнить сегментацию исходного текстурного изображения, используя для этой цели самоорганизующуюся карту Кохонена. На рис. 2 представлен алгоритм классификации и сегментации изображения самоорганизующейся картой Кохонена.

Алгоритм классификации данных, используя самоорганизующуюся карту Кохонена, заключается в следующем:

1. Чтобы можно было осуществить разметку карты, для каждого нейрона организуются счетчики классов, по числу известных классов исходного изображения.

2. Изображения признаков, полученные в результате процесса выделения набора признаков текстур из исходного обучающего изображения, осуществляемой с помощью многоканальной фильтрации, рассмотренной ранее, используются для раскрашивания поверхности карты (рис. 2).

3. При предъявлении на вход карты вектора признаков, определяющего конкретную точку исходного изображения, происходит активация только одного нейрона – нейрона-победителя. Так как, в этом случае используется изображение, применявшееся для обучения, нам априорно известно какому классу (или какой текстуре) соответствует данный вектор. Следовательно, данный нейрон-победитель является представителем данного класса данных в пространстве карты Кохонена.

4. В силу того, что количество нейронов намного меньше количества векторов признаков, схожие вектора будут вызывать активацию одного и того же нейрона. Наличие корреляции между текстурами приводит к тому, что при предъявлении векторов, соответствующих разным классам (текстурам), может произойти активация одного и того же нейрона, т.е. этот нейрон-победитель будет представлять в пространстве карты как данные одного класса, так и данные другого класса. Поэтому, для каждого нейрона организуются счетчики класса.

5. Далее на вход карты подается последовательно, один за другим, весь обучающий набор векторов признаков. Каждый раз, когда соответствующий нейрон становится победителем в конкурентной борьбе за предъявленный вектор, значение его счетчика соответствующего этому вектору класса увеличивается на единицу. После предъявления всего набора векторов, каждый нейрон карты получает метку класса (цвет), соответствующую классу с наивысшим значением счетчика этого нейрона (рис. 2).

С помощью раскрашенной карты Кохонена сегментация производится по следующему алгоритму (рис. 2):

1. Исходное текстурное изображение обрабатывается многоканальным (в общем случае) фильтром Габора. На выходе каждого канала формируется изображение характерных признаков. Эти изображения признаков образуют многомерное (в общем случае) пространство признаков. Соответственно, каждая точка исходного текстурного изображения представляется в пространстве вектором признаков.

2. Совокупность всех точек текстурного изображения определяет набор векторов признаков. Этот набор подается на вход карты Кохонена, вектор за вектором.

3. Каждый поданный вектор вызывает активацию определенного нейрона. Этот нейрон-победитель имеет определенный цвет на поверхности обученной карты Кохонена, определяющий класс (или текстуру), к которому принадлежит данный вектор.

4. Так как поданный вектор однозначно определяет точку исходного

изображения, то, следовательно, эта точка, принадлежит к тому же классу (или текстуре), что и вектор признаков.

5. Когда определен класс (или текстура), к которому принадлежит точка исходного изображения, этой точке назначается цвет, соответствующий этому классу.

6. В результате такой обработки всего набора векторов признаков получается сегментированное изображение, в котором каждый сегмент определенного цвета соответствует определенной текстуре в исходном изображении с учетом ошибки классификации.

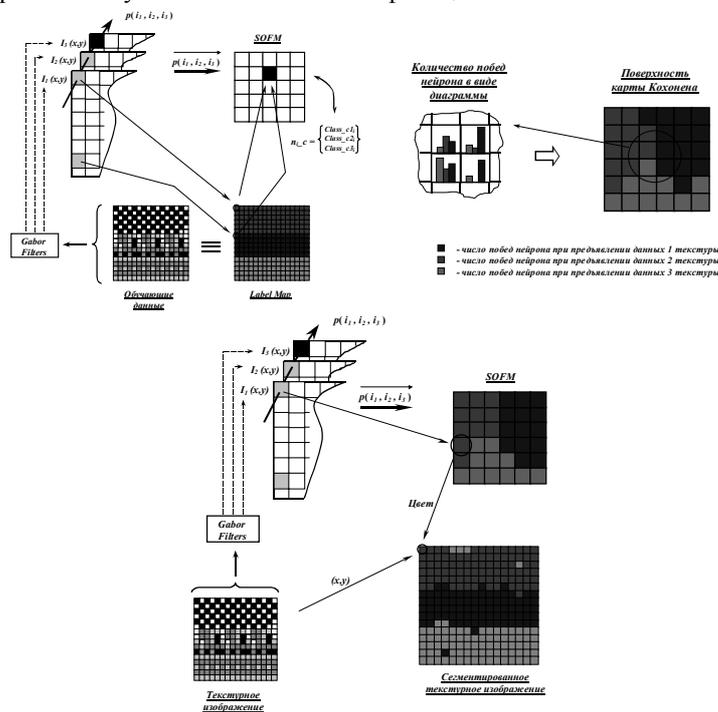


Рис. 2. Алгоритм классификации и сегментации изображения картой Кохонена.

Результаты

Предложенный метод был протестирован на изображениях, состоящих из текстур, взятых из альбома Бродаца. Изображения имели размер 256×256 точек и 256 градаций серого от 0 до 1 в системе HSB. На рис.3 представлено изображение, состоящее из текстур D16 и D77. На рис. 4 – D77, «знак +», «буква L».

Во всех случаях использования нейросетевого классификатора точность сегментации была выше, в отличие от случая с гауссовым классификатором.

Кроме того, использование нейросетевого классификатора по предлагаемой схеме (с использованием системы HSB) дает важное преимущество – при сегментации изображений можно использовать цветовую плоскость (H) для повышения точности сегментации натуральных изображений.

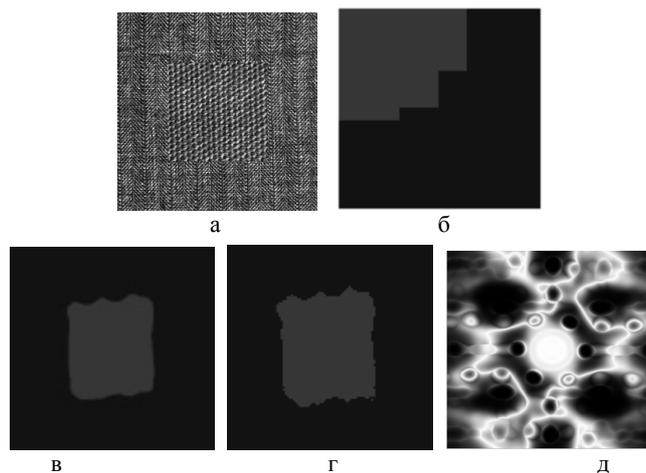


Рис. 3. Сегментация изображения из 2 текстур. $(U, V, \sigma_g, \sigma_p) = (-0.006, 0.429, 5, 10)$. Оригинальное изображение (а). Поверхность обученной карты Кохонена (б). Гауссовый классификатор (в) – ошибка 9,13%. Нейросетевой классификатор (г) – ошибка 6%. Ошибка сегментации от центральной частоты фильтра (д).

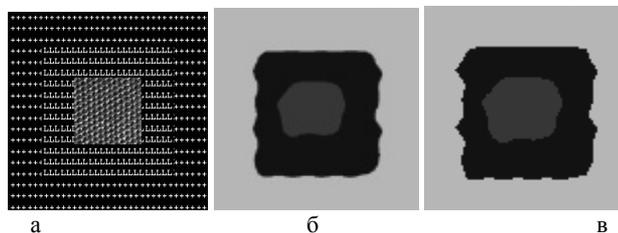


Рис.4. Сегментация изображения из 3 текстур. $(U, V, \sigma_g, \sigma_p) = (-0.086, 0.129, 5, 10)$. Оригинальное изображение (а). Гауссовый классификатор (б) – ошибка 16,83%. Нейросетевой классификатор (в) – ошибка 11,03%.

Литература

1. Tsymbal D., Emelyanov G.M. and other. An Algorithm of Multichannel Texture Segmentation // PATTERN RECOGNITION AND IMAGE ANALYSIS, Vol. 11, No 1., 2001. Pp 256-257.
2. Thomas P. Weldon, William E. Higgins, Dennis F. Dunn “Designing multiple Gabor filters for multi-texture image segmentation“. Optical Eng. 1999.

3. Thomas P. Weldon, William E. Higgins, Dennis F. Dunn. "Efficient Gabor Filter design for texture segmentation." Pattern Recognition, vol. 29, no 12, pp. 2005–2015, Dec. 1996.

Об одном алгоритме восстановления изображений по проекциям

Е.А. Черёмухин, А.И. Чуличков
(Москва)

Эксперименты по определению пространственной структуры объектов по проекциям традиционно называются томографическими. Однако на практике достаточно трудно осуществить эксперимент, в котором регистрируются «идеальные проекции», например, реальное сканирование объекта производится лучом конечной толщины, измерения сопровождаются случайной погрешностью и т.п. Это делает неадекватными методы классической томографии [1]. На основе методов теории измерительно-вычислительных систем [2] в работе предложен алгоритм восстановления изображений по измеренным с некоторой погрешностью «проекциям».

Рассмотрим так называемую «параллельную» схему сканирования в двумерном случае. Пусть имеется объект, заданный некоторой функцией $f(x), x \in R^2$. Результат измерения P «проекций» (интегралов по известным прямым) этого объекта с некоторой погрешностью можно записать в виде:

$$\xi_k = A_k f + v_k,$$

где $k = \overline{1, P}$, а вектор ξ_k некоторой размерности Q является результатом измерения проекций вдоль прямой, повернутой на угол φ_k . A_k - оператор, соответствующий измерению k -й проекции. v_k - случайная величина с нулевым математическим ожиданием $E v_k = 0$. Оценка функции f по результатам измерения множества проекций и погрешность этой оценки может быть получена при помощи методов теории измерительно-вычислительных систем [2].

Применение общих методов решения обратных задач редукции измерений к идеальному прибору, учитывающих полную модель измерения, требуют неприемлемо больших объемов вычислений. В работе показано, что в случае симметричной схемы сканирования возможно уменьшение размерности задачи без существенной потери точности. Восстановление изображения по «проекциям» производится с привлечением понятий собственного базиса и эффективного ранга модели измерений, основные идеи которых приводятся в работе [2]. Работа выполнена при поддержке

РФФИ, проекты № 03-01-00024 и № 02-01-00579.

Литература

1. Наттерер Ф. «Основы компьютерной томографии» // М.:Мир, 1991
2. Пытьев Ю.П. «Методы математического моделирования измерительно-вычислительных систем» // М.:Физматлит, 2002

Оптимизация процедуры линейной фильтрации в прикладных задачах обработки изображений

М.А. Чичева, Н.И. Глумов, В.В. Сергеев

(Самара)

Среди алгоритмов обработки цифровых изображений наиболее широко используется линейная фильтрация. С ее помощью решаются задачи обработки изображений – устранения линейных искажений, улучшения качества, выделения областей и подчеркивания контуров, обнаружения объектов (корреляторы) [1]. Такая обработка является весьма трудоемкой, т.е. обладает высокой удельной вычислительной сложностью (УВС), оцениваемой числом арифметических операций на отсчет изображения.

Целью данной работы является определение наиболее эффективных по критерию УВС алгоритмов линейной фильтрации в зависимости от размеров ИХ и изображения. Выбор производится среди трех возможных алгоритмов.

1. *Прямая реализация свертки:*

$$y(n_1, n_2) = \sum_{(l_1, l_2) \in D} h(l_1, l_2) x(n_1 - l_1, n_2 - l_2), \quad (1)$$

где $x(n_1, n_2)$ - входное изображение размером $N_1 \times N_2$, $h(l_1, l_2)$ - конечная вещественная импульсная характеристика (ИХ), значения которой отличаются от нуля только в прямоугольной области D размером $L_1 \times L_2$. УВС прямой реализации (1), очевидно, не зависит от размеров изображения:

$$U = 2L_1L_2 - 1. \quad (2)$$

2. *Реализация свертки в спектральной области* [1, 2]. УВС зависит от размеров $M_1 \geq N_1 + L_1 - 1, M_2 \geq N_2 + L_2 - 1$, для которых существует эффективный алгоритм дискретного преобразования Фурье (ДПФ), и равна

$$U(M_1, M_2) = W(M_1, M_2) / (N_1 N_2), \quad (3)$$

$$\text{где } W(M_1, M_2) = 2W_F(M_1, M_2) + 6M_1M_2 \quad (4)$$

- сложность свертки, определяемая сложностью $W_F(M_1, M_2)$ алгоритма

ДПФ и сложностью перемножения спектра изображения и частотной характеристики фильтра (спектра ИХ).

3. *Секционированная свертка* [1, 2]. В этом случае УВС, главным образом, зависит от размеров блока M_1, M_2 и сложности соответствующего алгоритма ДПФ и определяется одним из следующих соотношений:

- для изображения заданного размера:

$$U(M_1, M_2) = \frac{W(M_1, M_2)}{N_1 N_2} \left\lceil \frac{N_1}{M_1 - L_1 + 1} \right\rceil \left\lceil \frac{N_2}{M_2 - L_2 + 1} \right\rceil, \quad (5)$$

где $W(M_1, M_2)$ - общее количество операций, необходимое для обработки одного блока (4), $\lceil \cdot \rceil$ - операция округления "сверху";

- для полубесконечной полосы (такие изображения формируются, например, при дистанционном зондировании Земли):

$$U(M_1, M_2) = \frac{W(M_1, M_2)}{(M_1 - L_1 + 1) N_2} \left\lceil \frac{N_2}{M_2 - L_2 + 1} \right\rceil; \quad (6)$$

- для бесконечного по обеим координатам изображения (например, аэрокосмические изображения, объем которых составляет сотни мегабайт):

$$U(M_1, M_2) = \frac{W(M_1, M_2)}{(M_1 - L_1 + 1)(M_2 - L_2 + 1)}. \quad (7)$$

Приведенные оценки УВС (2), (3), (5)-(7) служат критериями при выборе алгоритма реализации свертки и его параметров (размеров блока и алгоритма ДПФ во втором и третьем случае). Отметим, что мы использовали следующие допущения:

- 1) время выполнения операций сложения и умножения считаем близким, что корректно для современных процессоров;
- 2) возможную оптимизацию обработки изображения на краях не учитываем, полагая, что размеры изображения значительно превышают размеры ИХ;
- 3) при обработке изображения методом секционированной свертки размеры блоков не меняются, т.е. применяется один конкретный алгоритм ДПФ, выбор которого зависит от размера блока.

Базовый алгоритм двумерного ДПФ

В основу процедуры линейной фильтрации в настоящей работе положен алгоритм секционированной свертки. С целью снижения УВС в качестве алгоритма двумерного ДПФ выбран построчно-столбцовый алгоритм (ПСА) [3], модифицированный для учета вещественности входных данных и ИХ фильтров. Этот алгоритм позволяет работать с прямоугольными блоками, что позволяет в ряде случаев достичь дополнительного снижения УВС свертки, обладает простой структурой.

Библиотека одномерных алгоритмов ДПФ, из которых формируется ПСА, включает в себя классический алгоритм ДПФ по основанию 4 [3] для длин 2^r ; алгоритм ДПФ длины 3^r с представлением данных в γ -кодах [4]; алгоритм ДПФ длины 6^r с представлением данных в γ -кодах; декомпозицию Гуда-Томаса для формирования алгоритмов промежуточных длин [3]. Такой набор алгоритмов, в достаточной мере расширяет классический случай, позволяя достичь снижения УВС свертки в 2 и более раз. В то же время все эти алгоритмы строятся единообразно, просты в реализации, эффективны.

Результаты

В докладе приводятся результаты оптимизации разработанной процедуры линейной фильтрации. Показано, что:

1) применение алгоритмов ДПФ из расширенного набора длин обеспечивает значительно меньшую УВС по сравнению с классическими ДПФ для длин 2^r - на 15-20%;

2) в ряде случаев наименьшая УВС обеспечивается при выборе не квадратных блоков, а прямоугольных – как в случае бесконечного изображения, так и конечного;

3) при росте размеров изображения размеры блока, соответствующие оптимальному алгоритму стабилизируются (стремятся к размерам, соответствующим модели бесконечного изображения) и зависят только от размеров ИХ.

Таким образом, представляемая библиотека алгоритмов и методика выбора оптимального алгоритма для реализации линейной свертки позволяет выбрать наиболее эффективный алгоритм для каждой конкретной ситуации.

Достоинствами предлагаемой процедуры являются возможность пополнения библиотеки базовых алгоритмов одномерного ДПФ, адаптивность по отношению к характеристикам (размерам) фильтров и обрабатываемых изображений, очевидные способы распараллеливания.

Эти возможности и будут определять дальнейшее развитие представленной процедуры.

Работа выполнена при поддержке Министерства образования РФ, Администрации Самарской области и Американского фонда гражданских исследований и развития (CRDF Project SA-014-02) в рамках российско-американской программы "Фундаментальные исследования и высшее образование" (BRHE).

Литература

1. Pratt W. K. Digital Image Processing. Vol.1, 2. A Wiley-Interscience Publication, New York, 1978.

2. Chernov V.M., Chichyeva M.A., Radchenko N.V., Sergeyev V.V. Optimization of structural and computational characteristics of algorithms of reconstruction of large images //Proceedings of International Conference "Automation, Control, and Information Technology" (ACIT), Novosibirsk, 2002, pp.429-434.
3. Blahut R.E. Fast algorithms for digital signal processing. Addison-Wesley Publishing Company, Inc., 1985.
4. Chernov V. M. Fast Algorithm of the Odd-Length Discrete Cosine Transform. Automatic Control and Computer Science, No 3, pp. 62-70, 1994.

Адаптация к голосу и среде в системе распознавания речи

В.Я. Чучупал, К.А. Маковкин., А.В. Чичагов

(Москва)

Введение

Методы адаптации к голосу диктора, каналу связи и окружающей среде имеют большое значение и широко используются в системах распознавания речи.

Необходимость проведения адаптации вызывается различиями в характеристиках речевого сигнала, использованного при оценивании параметров акустических моделей звуков, и того сигнала, что наблюдается в реальности.

Ниже рассматривается вариант адаптации системы распознавания речи, который основан на использовании кластеров акустических моделей, оцениваемых на основе стандартных процедур максимума правдоподобия.

Идея возможности подобного разделения используется практически давно – многие системы распознавания речи основаны на эмпирическом подходе с отдельным моделированием для мужских и женских голосов.

В первом разделе рассмотрен алгоритм кластеризации акустических моделей. Во втором разделе приведены результаты численных экспериментов.

Кластеризация акустических моделей

Кластеризация акустических моделей выполняется методом построения кластеров “снизу – вверх”. Алгоритм вычислений имеет следующий вид.

Пусть задано множество дикторов S_1, \dots, S_N .

Пусть S_i обозначает кластер (речевых параметров) и M_j обозначает модель данных для кластера S_i .

Определим “качество” модели M_j кластера S_i как величину правдоподобия данных:

$$L(S_i | M_j) = \sum_{o_j \in S_i} \log P(o_j | M_j), \text{ вычисленного на всех наблюдениях } o_j$$

из кластера S_i

Пусть S_{i+j} – кластер, образованный слиянием кластеров с индексами i и j . Определим расстояние между кластерами S_i и S_j от операции слияния кластеров S_i и S_j как величину изменения в правдоподобии данных в результате замены двух кластеров на их объединение:

$$L(S_i, S_j) = L(S_{i+j} | M_{i+j}) - (L(S_i | M_i) + L(S_j | M_j))$$

Алгоритм состоит из 8 шагов:

1. Построим начальное множество кластеров $S_i \dots S_N$, так что каждый кластер соответствует одному диктору, $S_i = \{S_{ij}\}$. Установим количество кластеров в N

2. Оценим для каждого кластера S_i его модель M_j .

3. Вычислим попарные расстояния между кластерами $L(S_i, S_j)$.

4. Найдем пару ближайших кластеров S_i и S_j .

5. Если расстояние между ближайшими $L(S_i, S_j)$ меньше порога или общее число кластеров N равно требуемому – идем на шаг 8.

6. Объединим кластеры S_i и S_j в новый кластер-потомок S_{i+j} и заменим родительские кластеры на их потомка в списке кластеров. Уменьшим число кластеров: $N = N-1$

7. Оценим модель данных M_{i+j} для кластера S_{i+j} . Идем на шаг 3.

8. Сохраним полученный список кластеров. Конец.

Результаты экспериментов

Численные эксперименты заключались в построении кластеров голосов дикторов на материале речевого корпуса данных, оценивании параметров кластерных моделей, измерении точности распознавания в зависимости от числа кластеров и правильности определения кластера, к которому относится запись голоса диктора.

Для обучения (оценки параметров распределений) использовался материал фонетической части речевой базы данных TeCoRus [3]. Для “доводки” моделей привлекался числовой материал того же речевого корпуса данных.

Для построения кластеров дикторов использовался материал фонетически сбалансированных фраз из TeCoRus от 70 дикторов, 36 мужчин и 34 женщин. Никакой предварительной фонетической сегментации или классификации векторов параметров не делалось – весь набор векторов параметров от одного диктора, включая участки пауз, использовался для построения одной “общей” модели голоса диктора.

В Таблице 1 ниже представлена сравнительная картина точности распознавания, как отдельно произносимых цифр, так и слитно произносимых последовательностей из цифр, которая наблюдалась при использовании двух и трех кластеров дикторов. Для измерений использовались цифры и последовательности цифр от 10 дикторов, не

входящих в обучающее множество. Дикторы выбирались случайным образом, однако сохранялось равное соотношение между мужчинами и женщинами.

Таблица 1. Сравнительная точность распознавания для кластерных моделей.

	1 кластер	2 кластера	3 кластера
Цифры	99.0	99.0	99.0
Последовательности цифр	89.0	94.0	91.0

Уменьшение точности для случая 3 кластеров связано, по видимому, только с уменьшением обучающей выборки – все ошибки распознавания относились к “мужскому” кластеру, который был разделен на два, с малым числом обучающих данных.

В следующей Таблице 2 приведена точность определения кластера диктора в процессе распознавания. Эта точность существенно превышала первоначальные оценки, то есть, оказалось, что о типе голоса (для 2-3 кластерных моделей) можно довольно точно судить по сравнительно коротким сегментам речевого материала.

Таблица 2. Точность распознавания кластера голоса диктора.

Число кластеров	2 кластера	3 кластера
Цифры	100.0	85.0
Последовательности (3 и более цифр)	100	99.0

Один из выводов, сделанных в результате анализа полученных кластеров, состоит в том, что при разбиении голосов дикторов на два класса решающую роль играл пол диктора – полученные кластеры полностью (на 100%) совпали с интуитивно понятными кластерами, образованными из мужчин и женщин. Дальнейшее разбиение (образование новых кластеров голосов) проходит внутри этих двух кластеров, причем здесь уже существенную роль играют не только характеристики голоса диктора, но и внешние условия записи.

Заключение

Рассмотрен вариант адаптации системы распознавания речи к голосу диктора, который основан на использовании кластеров акустических моделей, оцениваемых на основе стандартных процедур максимума правдоподобия.

Приведен алгоритм кластеризации акустических моделей. Приведены результаты численных экспериментов и показано, что реализация кластерных моделей позволяет увеличить точность распознавания речи.

Работа поддержана грантом РФФИ 02-01-00453.

Литература

1. Ney H., Aubert H. Dynamic programming search strategies: from digit strings to large vocabulary word graphs//Automatic Speech and Speaker Recognition/Kluwer Academic Publisher, 1996, pp.385-411.
2. Винцюк Т.К. Анализ, распознавание и смысловая интерпретация речевых сигналов//Киев. Наукова думка, 1987.
3. Kouznetsov V., Chuchupal V, Makovkin K., Chichagov A. Design and implementation of Russian telephone speech database//Proc. Int Workshop "Speech and Computer", SPECOM-99/ Moscow, 1999, pp.179-181.

Формирование траекторий из участков сети возможных траекторий

А.В. Шолохов

(Серпухов)

Введение

Рассматривается один из подходов к решению задачи формирования неразрывной траектории из участков сети возможных траекторий (СВТ) на основании измеренных геометрических параметров этой траектории.

Выбор участков сводится к решению задачи бивалентного линейного программирования (БЛП) [1]. При этом параметры линейной целевой функции определяются по измеренным геометрическим параметрам и соответствующим параметрам СВТ. Вводимые ограничения позволяют осуществить выбор участков, образующих неразрывную траекторию без ветвлений. Сформированная траектория является оптимальной в том смысле, что сумма величин отклонений между соответствующими параметрами является минимальной.

Постановка задачи

Пусть СВТ содержит m участков в виде прямолинейных отрезков (рис. 1). Некоторый j -й участок, $j < m$, определим математически посредством булевых переменных X_j следующим образом: $X_j = 1$, если j -й участок входит в число участков, составляющих искомую неразрывную траекторию; $X_j = 0$ - в противном случае.

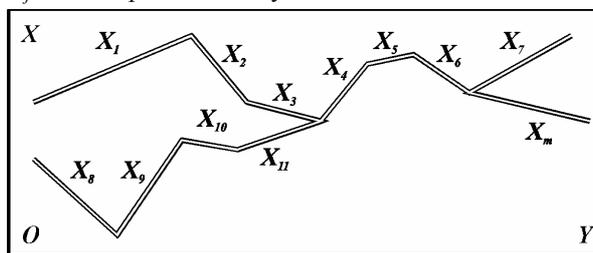


Рис. 1. Фрагмент сети возможных траекторий.

Зададим степень соответствия между участками СВТ и траекторией посредством коэффициентов соответствия c_j . Коэффициент соответствия может представлять собой, например, безусловную вероятность того, что j -й участок СВТ не входит в число участков, составляющих искомую траекторию. Числовые значения коэффициентов c_j рассчитываются по измеренным геометрическим параметрам и соответствующим параметрам участков СВТ.

Таким образом, каждый участок СВТ характеризуется булевой переменной X_j и коэффициентом соответствия c_j . Допустим, траектория включает n участков СВТ, $1 < n \leq m$. Тогда набор участков, составляющих оптимальное решение задачи выбора, может быть сформирован на основе минимизации линейной целевой функции, с учётом ограничений

$$J = \sum_{j=1}^m c_j \cdot X_j, \quad \sum_{j=1}^m X_j = n$$

Ограничения, исключающие разрывы и ветвления в формируемой траектории, могут быть приведены к системе неравенств

$$A \cdot X \leq B$$

где X – вектор, элементами которого являются X_j ; A, B – матрица и вектор, вид которых зависит от наличия общих точек участков конкретной СВТ. Один из способов формирования A и B будет рассмотрен ниже.

Обоснование ограничений

Один из подходов к формированию матрицы A и вектора B системы неравенств основан на определении логических функций аргументов X_j и последующем их преобразовании в систему неравенств.

Для обоснования ограничений, исключающих разрывы, рассмотрим фрагмент СВТ, включающий три участка X_1, X_2, X_3 (рис. 1). Всем комбинациям X_1, X_2, X_3 зададим значения логической функции f (таблица 1).

Таблица 1. Значения функции f

X_1	0	0	0	0	1	1	1	1
X_2	0	0	1	1	0	0	1	1
X_3	0	1	0	1	0	1	0	1
f	1	1	1	1	1	0	1	1

Функция f равна единице при всех комбинациях её аргументов за исключением комбинации $X_1 = 1, X_2 = 0, X_3 = 1$, которая соответствует разрыву траектории. Выражение для f может быть представлено в виде

$$f = \bar{X}_1 \vee X_2 \vee \bar{X}_3,$$

где черта над символом обозначает логическое отрицание. Наложим

ограничение на f , обеспечивающее отсутствие разрывов, в виде $f = 1$, и преобразуем логическое уравнение в систему неравенств

$$\begin{bmatrix} 1 & -1 & 0 \\ -1 & 1 & -1 \\ 0 & -1 & 1 \end{bmatrix} \cdot \begin{bmatrix} X_1 \\ X_2 \\ X_3 \end{bmatrix} \leq \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

Матрица в полученной системе содержит три типа элементов: -1 , 0 , 1 . Для произвольного числа участков СВТ, можно сформулировать правило формирования ограничений, обеспечивающих отсутствие разрывов. Главная диагональ матрицы A содержит единичные элементы. В каждой строке матрицы A элементы, имеющие связь (общую точку) с элементом на главной диагонали, равны -1 . Остальные элементы A и B равны нулю.

Ограничения, исключающие ветвления, определяются путём определения для каждой точки СВТ, принадлежащей трём и более участкам, логической функции, аргументами которой являются переменные X_j , и последующего преобразования логического уравнения в неравенство. Запишем в качестве примера ограничения для двух таких точек на рис. 1:

$$X_3 + X_4 + X_{11} \leq 2, \quad X_6 + X_7 + X_m \leq 2.$$

Определение коэффициентов соответствия

Ограничимся рассмотрением упрощённого примера определения коэффициентов соответствия c_k . В качестве измеряемых параметров используем углы ориентации участка СВТ и касательной в точке траектории.

Рассмотрим некоторый участок ЦКД, обозначенный X_k , имеющий угол ориентации α_k . Пусть траектория объекта представлена тремя участками СВТ ($n = 3$), ориентация которых определяется углами $\alpha'_1, \alpha'_2, \alpha'_3$. Для этих участков определим частные коэффициенты в диапазоне $0 \dots 90^\circ$

$$c_{k1} = |\alpha_k - \alpha'_1|, \quad c_{k2} = |\alpha_k - \alpha'_2|, \quad c_{k3} = |\alpha_k - \alpha'_3|$$

Коэффициент соответствия c_k участка X_k определяется экстремальным значением коэффициентов c_{k1}, \dots, c_{kn} . В задаче БЛП на минимум коэффициент c_k определяется, как

$$c_k = \min\{c_{k1}, \dots, c_{kn}\}, \quad k = 1, \dots, m.$$

Отметим, что в качестве измеряемых геометрических параметров целесообразно использовать инвариантные по отношению к повороту и переносу системы координат параметры (длину участков, приращения углов ориентации и пр.)

Рассмотренный подход нашёл применение при решении задач навигации наземных объектов с привлечением цифровых карт местности [2, 3].

Литература

1. Таха Х. Введение в исследование операций: в 2-х книгах: Пер. с англ. – М.: Мир, 1985.
2. Дмитриев С.П., Степанов О.А., Ривкин Б.С., Кошаев Д.А., Чанг Д. Оптимальное решение задачи автомобильной навигации с использованием карты дорог//Гироскопия и навигация. – 2000. - №2(29).
3. Шолохов А.В. Определение текущего местоположения объекта по цифровым картам дорог без начальной настройки навигационных систем счисления.//Навигация и управление движением. Материалы III КМУ. – СПб.: ГНЦ РФ - ЦНИИ «Электроприбор», 2001. – 244с.

Прогноз сильных землетрясений в линейных зонах

А.М. Шурыгин, М.С. Стригунова

(Москва)

Большинство сильных землетрясений происходит в вытянутых линейных зонах на глубине меньшей 60 км, что даёт возможность свести три пространственные координаты к одной: положению X на линии зоны. Второй координатой является время t . Разделим землетрясения по силе на три группы: немногочисленные сильные, которые и надо прогнозировать, умеренные, среди которых есть предикторы прогноза, и слабые, для прогноза мало пригодные. Исключим последнюю группу. Перейдём к дискретным переменным, разделив линейный регион по X на b трансформных зон и измеряя время t в сутках. На рис.1 вверху изображено деление цепи Курильских островов на $b=5$ зон. Каталог землетрясений заменим булевой матрицей $K = \{k_{uv}\}$, элементом которой будет единица, если в соответствующей зоне и соответствующий день произошло по крайней мере одно землетрясение, и нулём в противном случае.

Для каждого сильного землетрясения выделим предысторию, например, 12-летнюю. "Листы" предысторий объединим в один "трафарет" T , совместив сильные землетрясения, находящиеся в нулевых строках листов, и элемент их совмещения будем считать центром трафарета и обозначим через O . Наложим эту точку на точку прогноза (i, j) каталога, получив трафарет T_{ij} . **Операцию скользящего умножения** матрицы K матрицей T по окну w на пересечении $K \cap T$ обозначим символом \prod_w и определим так:

$$K \prod_w T = \left\{ k_{uv} \sum_w t_{uv} / \sqrt{w} \right\}, \text{ где символом } \sum_w \text{ обозначено суммирование}$$

элементов в скользящем по времени окне размером w с центром в $t = u$.

Обозначив символами $S(A)$ сумму элементов матрицы A , определим прогнозную функцию в точке (i, j) равенством

$$d_{ij} = S(K \prod_w T_{ij}).$$

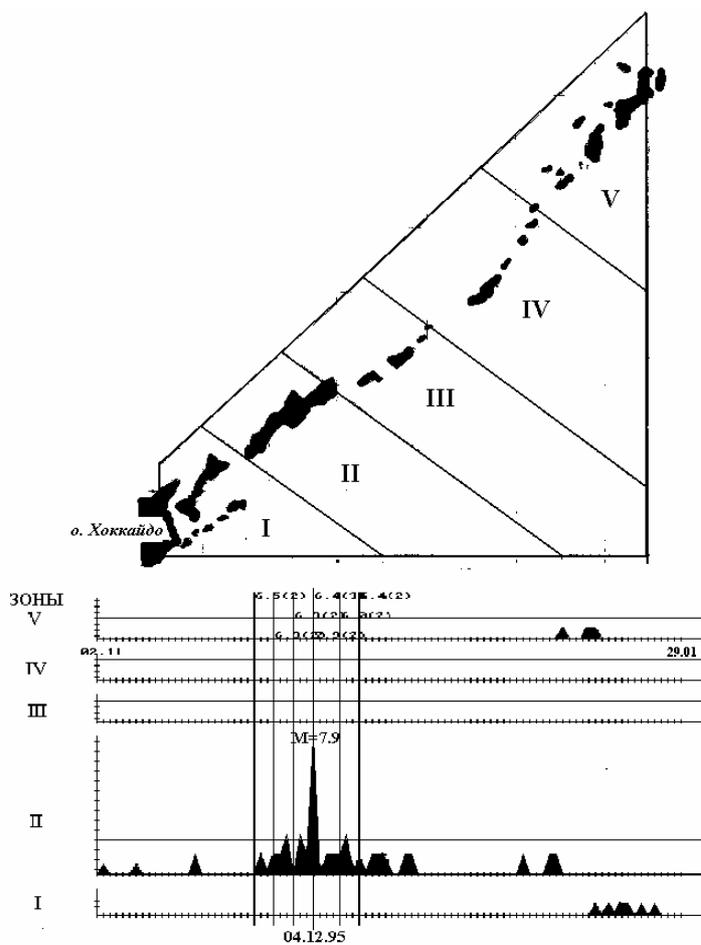


Рис1. Разделение Курильских островов на зоны (вверху) и прогнозные функции на период с 01.11.95 по 29.01.96 (внизу). Максимум во II зоне отвечает сильному землетрясению 04.12.95 с магнитудой $M=7.9$.

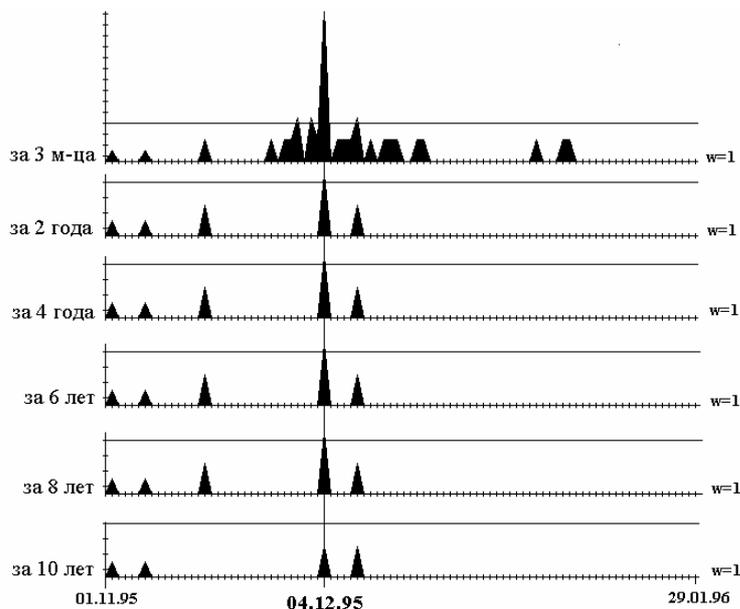


Рис.2. Ретроспективные прогнозы сильного Курильского землетрясения 04.12.95.

Эта функция была предложена в статье [2]. Она действительно имеет повышенные значения на сильных землетрясениях, но выделяет также более слабые, а иногда даёт ложные максимумы, очевидно, из-за присутствия "шумовых" землетрясений в трафарете. Чтобы избавиться от них, в трафарете были отобраны лишь "информативные" землетрясения согласно [1]. Прогноз с редуцированным трафаретом даёт хорошие результаты, иллюстрируемые ретроспективным прогнозом рядового сильного землетрясения на рис.1 внизу. Интересно, что прогностическая способность алгоритма сохраняется и при значительном удалении по времени банка данных от точки прогноза (рис.2).

Наши прогнозы помещаются на сайте www.cs.ru/cito/eq.

Литература

1. Шурьгин А.М. Прикладная стохастика: робастность, оценивание, прогноз. М.: Финансы и Статистика, 2000, 224 с.
2. Shurygin, A.M., Strigunova, M.S. Recognition of seismic danger. // Pattern Recognition and Image Analysis, 2003, v.13, no.2, p.9-13.

Анализ данных и извлечение знаний с помощью Универсального Классификатора

В.Н. Юдин
(Москва)

Введение

Универсальный Классификатор (УК) [3], созданный в Институте Системного Программирования РАН, первоначально был разработан для решения задач *распознавания образов*. Типичная задача распознавания образов состоит в классификации *объектов исследования*. Объект представляется своим формализованным описанием - вектором значений *признаков*. Объекты можно рассматривать как точки в пространстве признаков. Для распознавания объектов в пространстве признаков формируются *кластеры* – группы близких по признакам объектов. Распознавание состоит в отнесении объекта к одному из кластеров либо на основе попадания объекта в кластер, либо близости этого объекта к кластеру.

УК может эксплуатироваться в совокупности с другими системами в качестве модуля или независимо, как инструмент исследователя, в областях, где требуется применять классификацию объектов. Среди выполняемых функций – классификация, выявление кластеров, поиск аналогов. УК используется в системе "Спутник Врача", предназначенной для информационной поддержки врачебных решений в диагностике и выборе лечения.

Проблема извлечения знаний из баз и хранилищ данных (Data Mining) находится в центре внимания ведущих исследователей с начала 90-х годов. При исследовании данных используется большое число различных методов и их комбинаций. УК может быть использован для этих целей, прежде всего по своему прямому назначению: для классификации и кластеризации.

С помощью *классификации* выявляются признаки, характеризующие группу, к которой принадлежит тот или иной объект. Это делается через анализ уже классифицированных объектов с помощью некоторого набора правил. Исследование начинается, когда данные предварительно расклассифицированы на обучающее множество данных и данные, по которым проверяется найденная модель.

Методы *выявления кластеров* позволяют разделить изучаемую совокупность объектов на группы по каким-нибудь признакам. Кластеризация отличается от классификации тем, что сами группы заранее не заданы.

При использовании многомерных моделей на практике необходимо предварительно решить, сколько признаков, и какие именно признаки учитывать. Используемые при исследовании данных *регрессионные методы* применяются, главным образом, для обнаружения числовых зависимостей в

данных. Они основаны на традиционных статистических методиках, в первую очередь на регрессионном анализе, и включают массивный перебор самых разнообразных гипотез, поэтому требуют значительного времени вычислений. По результатам такого исследования можно оценить вклад каждого признака, определив знак и силу этого влияния. Одна из целей исследования - минимизировать число признаков, оставив только признаки, существенные для оценки целевого фактора.

В УК добавлена новая функция - *исследование признаков*. Ее отличие от традиционных методов регрессии заключается в том, что целевым фактором является принадлежность исследуемого объекта тому или иному кластеру. Соответственно, вклад каждого признака определяется тем, насколько разделены кластеры по этому признаку. Процедура вычисления при этом значительно упрощается, позволяя перейти от перебора к сравнению признаков и границ кластеров.

Метод

В реализованном в УК методе кластер представляется в пространстве признаков как многомерный параллелепипед, охватывающий объекты кластера. При оценке исследуемого объекта каждый его признак сравнивается с соответствующим диапазоном в описании кластера, вне связи с другими признаками. Если объект попадает в область пересечения кластеров, их нужно дифференцировать друг от друга, добавляя объекту новые признаки. В этом случае полезно знать, какие признаки стоит добавлять в первую очередь, чтобы добиться разделения.

Анализ чувствительности позволяет выявить силу влияния признаков на разделение кластеров. На рис. 1 показаны три кластера в пространстве признаков x_1 и x_2 . Если сравнивать кластеры 1 и 3, каждый из признаков является определяющим для разделения кластеров. С другой стороны, признак x_1 не является определяющим для разделения кластеров 1 и 2.

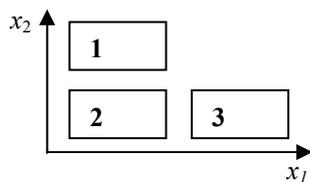


Рис. 1. Влияние признака на разделение кластеров.

Значимость признака для выбранных кластеров показывает, насколько разделены кластеры по этому признаку. Определим ее как отношение числа объектов, обладающих этим признаком, к числу попаданий этого признака в границы кластеров. Она равна 1, когда кластеры разделены, и меньше 0, когда кластеры пересекаются. На рис. 2 - 9 объектов в двух кластерах. У 4 из них признак x_1 одновременно попадает в два кластера. Значимость признака

x_1 равна $9/(9+4) = 9/13$.

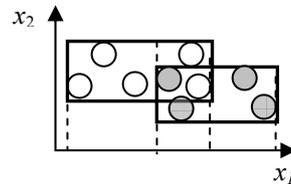


Рис. 2. Значимость признака x_1 .

Пусть *степень пересечения* кластеров - это суммарное количество объектов в области пересечения кластеров, если они пересекаются, и нуль в противном случае. *Чувствительность к отсутствию признаков* определяется тем, насколько увеличится степень пересечения кластеров в подпространстве, ортогональном подпространству исследуемых признаков. Реализуется это через классификацию объектов указанных кластеров до и после перехода в подпространство. Если чувствительность к отсутствию признака не равна нулю, значит, этот признак существен для разделения кластеров. Регрессия в этом смысле означает сохранение только существенных признаков.

Заключение

В УК реализованы методы, область применения которых достаточно широка. Применяемые методы - классификация, кластеризация и исследование признаков - значительная часть способов извлечения знаний, используемых в настоящее время. Учитывая, что, главной проблемой методов обнаружения закономерностей является проблема перебора вариантов за приемлемое время, УК позволяет значительно сократить затраты на исследования.

Литература

1. Ту Дж., Гонсалес Р.. Принципы распознавания образов // Мир, М, 1978.
2. Киселев М., Соломатин Е. Средства добычи знаний в бизнесе и финансах // Открытые системы, 4, 1997, с.41-44.
3. Yudin V. N., Bespaev A. T. Application of Cluster Analysis for Searching for Analogies in Diagnostics and Choice of Treatment in the "Doctor's Partner" System // Pattern Recognition and Image Analysis Vol. 13 No. 2 2003 pp. 387-390.

ОГЛАВЛЕНИЕ

I. Математическая теория распознавания.....	3
<i>Р.А. Абусев</i> О групповых процедурах классификации распределений Парето	3
<i>К.Р. Айда-заде, Дж.З. Гасанов, Э.Э. Мустафаев</i> Об использовании баз знаний для повышения интеллектуальности систем распознавания.....	6
<i>М.Б. Айдарханов</i> Структурный подход к построению групповых классификаций.....	8
<i>Н.Н. Апраушева, Н. Моллаверди, С.В. Сорокин, А.Е. Торхов</i> Вычисления стационарных точек плотности вероятностей гауссовой смеси.....	11
<i>Н.Н. Апраушева, С.В. Сорокин</i> Об условиях унимодальности простейшей гауссовой смеси	14
<i>Е.В. Бауман, А.А. Дорофеюк</i> Методы стохастической аппроксимации в задачах кластерного анализа.....	16
<i>Е.В. Бауман, А.А. Дорофеюк, Г.В. Корнилов</i> Задача оптимальной кусочной аппроксимации с использованием методов классификационного анализа.....	19
<i>В.Б. Бериков</i> Оценивание качества дискретной распознающей системы по обучающей выборке	22
<i>А.Н. Блоконенков</i> Об одной модели алгоритма классификации для задачи с K непересекающимися классами	25
<i>Ю.А. Бродская</i> Распознавание образов при заданных ограничениях.....	30
<i>Н.П. Брусенцов, Ю.С. Владимирова</i> Конструктивная компьютеризация булевой алгебры	33
<i>А.С. Вальков</i> О субквадратичных алгоритмах синтеза плоских представлений конечных метрических конфигураций.....	35
<i>В.И. Васильев</i> Комбинированные индуктивные методы в редуцированных алгоритмах.....	35
<i>Ю.Г. Васин, Л.И. Лебедев</i> Ортогональные скелетоны в задаче оптимизации вычислительной сложности алгоритма ДАРБИ.....	38

<i>Д.П. Ветров</i> Об одном способе регуляризации некорректно поставленных задач распознавания образов.....	41
<i>А.А. Викентьев., Р.А. Викентьев</i> Информативность и близость на формулах – знаниях экспертов в конечном классе моделей с метриками	44
<i>К.В. Воронцов</i> О комбинаторном подходе к оценке качества обучения алгоритмов.....	47
<i>Ю.Е. Гагарин</i> Последовательный алгоритм распознавания объектов при стохастических исходных данных	49
<i>С.А. Гальперин</i> Дифференцируемость функции уклонения в R^n	52
<i>Ю.И. Горелов</i> О регулярности и разрешимости задач распознавания с равномоными классами.....	55
<i>С.И. Гуров, О.Ф. Уткина</i> Определение вероятности ошибки распознавания с восстановлением её априорного распределения	56
<i>Ф.Ф. Дедус</i> Спектральные методы в задачах обработки информации	59
<i>Е.А. Демьянов, Е.В. Дюкова, А.С. Инякин</i> Экспериментальное исследование алгоритмов построения неприводимых покрытий булевых матриц	61
<i>А.В. Дергузов, С.А. Махортых</i> Анализ и идентификация функций, заданных на сфере	65
<i>А.А. Докукин</i> Об одном подходе к оптимизации АВО.....	68
<i>В.И. Донской, Ю.Ю. Дюличева</i> Алгоритмы синтеза γ -редуцированного эмпирического леса	71
<i>А.А. Дорофеюк</i> Методы классификационного анализа данных в задаче структурного прогнозирования динамических объектов	74
<i>А.А. Дорофеюк, Е.В. Бауман</i> Классификационные методы анализа сложноорганизованных данных.....	76
<i>А.Г. Дьяконов</i> Решение задач распознавания логическими алгоритмами, ориентированными на бинарную информацию	79

<i>Е.В. Дюкова, А.Б. Пьянов</i> Асимптотика логарифма числа тупиковых σ -покрытий целочисленной матрицы	80
<i>С.В. Елисеев, К.В. Воронцов</i> Сравнительный анализ монотонной и выпуклой коррекции в задачах классификации	83
<i>Г.С. Животников</i> О задаче оптимального оценивания параметров объекта по его изображению	85
<i>А.Г. Ивахненко, А.Б. Надирадзе, Г.А. Ивахненко, Е.А. Савченко</i> Развитие алгоритмов самоорганизации по методу группового учета аргументов	87
<i>С.В. Ильинский, Ю.Г. Сметанин</i> Об ассоциативной памяти с безошибочным обучением	93
<i>А.В. Кельманов, Л.В. Михайлова</i> Апостериорное совместное обнаружение заданного числа фрагментов в квазипериодической последовательности и ее разбиение на серии одинаковых фрагментов по образцу	96
<i>А.В. Кельманов, С.А. Хамидуллин</i> Максимально правдоподобное апостериорное обнаружение квазипериодически повторяющегося фрагмента числовой последовательности в условиях шума и потери данных	100
<i>Л.О. Кириченко, О.И. Синельникова</i> Динамика модели роста под действием возмущающих факторов	103
<i>Н.В. Ковшов, В.В. Рязанов</i> Генетический алгоритм поиска логических закономерностей по прецедентам для решения задач распознавания	106
<i>И.В. Котельников</i> Адаптивный алгоритм распознавания образов на основе оптимальных тупиковых нечётких тестов и синдромов	109
<i>В.В. Крепец</i> Нейронные сети максимальной устойчивости как альтернатива робастным нейронным сетям	112
<i>Б.В. Крыжановский, Л.Б. Литинский</i> Ассоциативная память на нелинейно-оптических принципах	116
<i>Б.В. Крыжановский, Л.Б. Литинский</i> Непереборный алгоритм отыскания глобального минимума одного функционала	119

<i>В.М. Крыжановский, Л.Б. Литинский</i> Повышение емкости памяти модели Хопфилда.....	122
<i>Л.И. Куликова</i> Предварительная обработка данных в процессе их аналитического описания с помощью ортогональных рядов.....	124
<i>Г.С. Лбов, Т.А. Ступина</i> Исследование зависимости критерия качества прогнозирования многомерной переменной от объема выборки и сложности решающей функции.....	127
<i>А.Н. Леухин, Д.Г. Хафизов</i> Оценка параметров вращений трехмерного группового точечного объекта без предварительной нумерации формирующих точек.....	130
<i>А.В. Марусяк, Ю.Л. Шередко</i> Задачи различения.....	133
<i>В.Л. Матросов, В.А. Горелик, С.А. Жданов, О.В. Муравьева</i> Коррекция данных в задаче классификации.....	136
<i>В.Л. Матросов, Е.А. Иванова, С.А. Жданов</i> Синтез алгоритма с заданным качеством.....	137
<i>В.В. Моттль, О.В. Красоткина</i> Беспереборная минимизация числа аргументов в задаче восстановления линейной регрессионной зависимости по малым обучающим выборкам ...	138
<i>В.В. Моттль, О.С. Середин</i> Вероятностный принцип формирования потенциальных функций на множествах объектов произвольной природы для беспризнакового распознавания образов и восстановления зависимостей.....	141
<i>А.Б. Надирадзе</i> Проблемы использования МГУА при неполных и неточных исходных данных	145
<i>В. М. Неделько</i> Оценка смещения эмпирической оценки риска решающей функции.....	148
<i>Ю.И. Неймарк, Л.Г. Теклина</i> Адаптивная управляемая динамическая система распознавания на основе метода наименьших квадратов	150
<i>Ю.И. Неймарк, Л.Г. Теклина</i> Сжатие описания для изменяющихся массивов данных	153
<i>Г.В. Никитов</i> О метрических методах интеллектуальной обработки данных	156
<i>М.А. Никифоров</i> Задачи классификации со связанными объектами	157
500	

<i>А.Н. Панкратов</i> Исследование и классификация функций посредством глубокого разложения в ортогональные ряды.....	159
<i>Н.В. Песков, А.А. Сахаров</i> Об одном подходе к понижению значности исходной информации в задачах распознавания	160
<i>А.В. Пролубников, Р.Т. Файзуллин</i> Алгоритм спектрального расщепления проверки изоморфизма графов и его приложения.....	162
<i>С.Б. Пиеничников, Б.С. Пиеничников</i> Гиперкомплексный анализ числовых последовательностей размерности 2^n	165
<i>Ю.П. Пытьев</i> Предельные теоремы теории возможностей.....	166
<i>А.А. Рожнецов</i> Предельно достижимые возможности при распознавании многомерных сигналов	169
<i>О.В. Сенько, А.В. Кузнецова</i> Метод предварительной селекции признаков	171
<i>А.Ю. Сметанин</i> О построении корректных алгоритмов вычисления оценок как задаче условной оптимизации.....	173
<i>В.А. Стадников, С.Н. Чуканов</i> Формирование поверхностей уровня по векторному полю	175
<i>В.В. Стрижов, В.В. Шакин</i> Прогноз и управление в авторегрессионных моделях	178
<i>Р.К. Тетуев</i> Аналитическое описание зашумленных исходных сигналов по функциям Сонина-Лагерра и получение их первых производных	181
<i>А.В. Тимофеев</i> Динамическая диагностика функций и состояний управляемых систем.....	184
<i>А.В. Тимофеев</i> Методы обучения и самоорганизации полиномиальных нейронных сетей в задачах распознавания образов	187
<i>О.Е. Трофимов, А.С. Загоруйко</i> Интервальный критерий синхронизации – десинхронизации сигналов	191
<i>Б.З. Угольникова, С.А. Жданов</i> Об одном методе получения оценок.....	194

<i>О.В. Фаломкина</i>	
О стохастической модели меры возможности.....	196
<i>М.Ю. Хачай</i>	
О вычислительной сложности задачи о минимальном комитете	198
<i>В.М. Хачумов, Е.В. Ксенофонтова</i>	
Образный анализ и диагностика сложных процессов.....	201
<i>В.И. Хомич</i>	
О свойстве простой подстановки для неклассических логик.....	204
<i>Хоссейн Беврани</i>	
Обобщение метода Монте-Карло для вычисления определенных интегралов	208
<i>А.А. Черепнин</i>	
О радиусах разрешимости и регулярности задач распознавания	210
<i>Д.А. Черепнин</i>	
О решетке функциональных сигнатур	211
<i>В.М. Чернов</i>	
Неоднозначность разложения на множители, канонические системы счисления в квадратичных кольцах и параллельные алгоритмы вычисления свертки	212
<i>Ю.В. Чехович</i>	
Мощности окрестностей в задачах выделения трендов	215
<i>З.М. Шибзухов</i>	
Конструктивный метод обучения с учителем рекуррентного $\Sigma\Pi$ -нейрона	216
<i>Л.А. Шульга, Н.Г. Федотов</i>	
Структуры распознающих систем на основе стохастической геометрии....	219
<i>С.А. Яковлев</i>	
О формировании набора эталонов в базах данных	222
<i>А.Е. Янковская</i>	
Синтез смешанных логических тестов на основе ускоренных шагово- циклических алгоритмов спуска	224
<i>А.Е. Янковская, С.И. Колесникова</i>	
Сравнительный анализ методов получения весовых коэффициентов признаков в задаче распознавания образов	227
II. Прикладные задачи и системы распознавания.....	230
<i>К.Р. Айда-заде, С.Г. Талыбов, Э.Э. Мустафаев</i>	
Многоуровневая система распознавания рукописных форм	230

<i>Э.М. Алиев, Н.Т. Сотиволдиев, А.Х. Шералиев</i> Распознающие модели в технической диагностике объекта управления	233
<i>Д.Г. Асатрян, Г.М. Бабаян</i> Различение отражающих участков антенного полигона по измерениям суммарного поля в рабочей зоне.....	236
<i>В.Ф. Бабкин, И.М. Книжный, К.Е. Хрекин</i> Сжатие без потерь или с ограниченными потерями статических полутоновых изображений	239
<i>Д.С. Баскаков, Л.М. Местецкий</i> Автоматизация палеографического исследования древних рукописей	242
<i>А.В. Бовырин, К.В. Родюшкин</i> Статистическая оценка цветовых компонент губ и лица для вычисления контуров рта с использованием деформируемых шаблонов.....	245
<i>Ф.Г. Бойков, Т.К. Старожилова</i> Применение вейвлет-анализа сигнала в системе распознавания речи	247
<i>М.С. Босняков</i> Методы и подходы к решению обратной задачи акустической термотомографии при наличии шума	250
<i>Д.Ю. Боснякова, Ю.В. Гуляев, Ю.В. Обухов</i> Метод поиска признаков пространственно-временных связей функционирования участков головного мозга человека в задаче пассивного радиотеплового картирования.	253
<i>С.П. Ботуз</i> Синтез социально-экономических моделей идентификации интерактивных систем программного управления	256
<i>С.П. Ботуз, А.В. Кулемин, С.П. Лукницкий</i> Методы идентификации и классификации процессов взаимодействия субъектов и объектов интеллектуальной собственности	258
<i>А.В. Бутвина</i> Выбор начальной точки процесса векторизации контурных изображений в задачах распознавания	260
<i>М.Н. Вайнцвайг, М.Н. Полякова</i> Архитектура системы представления зрительных динамических сцен в терминах понятий.....	261
<i>В.П. Вежневцев, А.А. Андреева, А.А. Дегтярева</i> Сравнительный анализ методов сегментации кожи на цветных изображениях	264

<i>Д.П. Ветров, Д.А. Кропотов</i> Программный комплекс для проектирования экспертных систем «ExSys»	266
<i>Л.М. Воронова, Ю.И. Журавлев</i> Некоторые аспекты прогнозирования результатов агроэкологически верных вариантов земледелия в реальных условиях хозяйства	269
<i>С.Н. Ганебных, М.М. Ланге</i> Анализ сцен на основе применения древовидных представлений изображений	271
<i>В.В. Гептнер, А.С. Хайдар</i> Сравнительное исследование эффективности различных описаний речевых сигналов в задаче верификации дикторов	275
<i>С.В. Геращенко, В.Е. Анциперов</i> Экспериментальные результаты по выделению графических примитивов в задачах распознавания контурных изображений.	278
<i>Ю.И. Горелов, В.А. Сушкин</i> Прогнозирование аномальных режимов динамических электрохимических систем методами распознавания образов	279
<i>И.С. Городничев</i> О критериях оценки поисковых систем	280
<i>И.В. Грибков, А.В. Захаров, П.П. Кольцов, Н.В. Котович, А.А. Кравченко, А.С. Куцаев, В.К. Николаев</i> Тестирование алгоритмов предварительной обработки изображений	283
<i>В.А. Гришин</i> Телевизионный датчик системы управления движением	286
<i>С.Д. Двоенко, В.Н. Абаджев</i> Формирование словаря для языка сокращенного описания программного кода	289
<i>А.О. Евдокимов, И.Л. Егошина</i> Восстановление объекта из изображений его частей	292
<i>А.Н. Ефимов</i> Применение имитационного моделирования для оценки качества метрик в задачах анализа клиентских сред	295
<i>В.М. Ефременкова, И.А. Жлябинкова, Ю.Г. Сметанин</i> Информационный мониторинг публикаций по нейросетевым исследованиям	297
<i>А.П. Жабко, Д.Н. Клименко, <u>В.Г. Рот</u>, А.Л. Шапошников</i> Новые методы повышения точности математического анализа электропривода намоточных устройств для химических нитей	300

<i>А.П. Жабко, В.А. Климов, В.Л. Литвинчук, Д.Н. Клименко</i> Ноль-схема интегрирования, как аппарат для уточнения решения при математическом моделировании оборудования для производства химических нитей	301
<i>А.П. Жабко, Е.Г. Маежов, А.С. Донской, Р.Р. Саакян</i> Формирование признаков пространства свойств синтетических нитей на основе акустических сигналов их возбуждения	302
<i>А.А. Жарких</i> Конформная стеганография звукового сигнала в звуковом сигнале	305
<i>А.А. Жарких</i> Распознавание звуковых сигналов на основе конформного анализа	308
<i>Ю.И. Журавлев, В.В. Рязанов, О.В. Сенько, А.С. Бирюков, Д.П. Ветров, А.А. Докукин, Н.Н. Катериночкина, Д.А. Кропотов, А.С. Обухов, М.Ю. Романов, И.В. Рязанов, Ф.Б. Челноков</i> Разработка универсальной программной системы интеллектуального анализа данных, распознавания и прогноза	311
<i>А.М. Захаров, М.И. Кумсков, Л.А. Пономарева</i> Описание молекулярных графов в задаче «структура-свойство» с использованием нечеткой логики	314
<i>А.М. Захаров, М.И. Кумсков, Л.А. Пономарева, Л.К. Маслова</i> Представление молекулярных графов «нечеткими треугольниками» при прогнозировании биологической активности	316
<i>С.В. Зинченко, М.С. Хозяинов, О.А. Якушина</i> Программный комплекс для решения задач классификации минералов на основе алгоритма обратного распространения ошибки	318
<i>Т.В. Казакова, В.В. Шакин</i> Исследование основных краткосрочных экономических показателей РФ ..	320
<i>Н.Н. Киселева</i> Компьютерное конструирование неорганических веществ с использованием методов обучения ЭВМ	323
<i>М.А. Коганов, А.В. Коганов, П.П. Кольцов</i> Метод ТЕМП – распознавания музыкальных произведений	327
<i>Д.В. Колядин</i> Анализ динамических кривых применительно к задаче верификации рукописной подписи	330
<i>А.В. Копылов, А.С. Ермаков, А.И. Татарчук</i> Процедура совмещения изображений для формирования симметричных мер сходства	333

<i>А.В. Корякин</i> Принципы реализации комплексного распознавания искусственных космических объектов по многоспектральной видовой информации.....	336
<i>А.В. Кревецкий, С.Е. Чесноков, А.С. Авраменко</i> Совместный учет яркостной и координатной информации при опознавании астроориентиров	339
<i>Е.Н. Кузнецов, Ш.Р. Сюняев, В.Г. Туманян</i> Выравнивание аминокислотных последовательностей для независимых позиционных наблюдений	341
<i>М.И. Кумсков, С.Ю. Сергунин, К.М. Квашинин</i> Итерационное формирование описаний изображения, управляемое моделью объекта, в задаче распознавания	343
<i>П.Г. Курочкин</i> Совместное применение астролометрической методики и нейронных сетей для прогнозирования фондовых индексов	347
<i>С.Н. Ломакин, Д.В. Солдатенков, С.А. Яковлев</i> Принятие решений о значимости программных продуктов путем их сравнения с аналогами-эталоном в базе данных учебно-научных работ ...	351
<i>Т.И. Лучшева</i> Построение математической модели для анализа данных МЧС	352
<i>Е.Г. Маежов, В.А. Климов, В.А. Чайкин, А.Г. Усов</i> Ориентирующая информация по оценке внутренней структуры химических нитей на основе выходных характеристик их механических моделей.....	355
<i>Е.Г. Маежов, Р.Р. Саакян, В.А. Чайкин, А.Г. Усов, И.А. Шпехт</i> Осредненные параметры приведенных структур химических нитей с учетом взаимодействия элементов структур в единой нити	357
<i>Вл.Д. Мазуров, Л.Н. Юрченко, Н.В. Кисляк.</i> Полнота и плотность алгебры нейронных сетей в пространстве задач - основа приложений распознавания и нейронных сетей в биологии и медицине	358
<i>В.Л. Матросов, Е.Г. Перепелицин, С.М. Кулясов</i> Методы выравнивания освещенности и контрастирования изображений...	360
<i>С.А. Махортых, А.Р. Гатина, С.А. Костарев, С.А. Рыбак</i> Компьютерные методы виброакустического прогноза	361
<i>Л.М. Местецкий, А.Г. Нефедов</i> Восстановление следа пера при анализе сканированных рукописных документов.....	364

<i>Л.М. Местецкий, И.А. Рейер</i> Непрерывная гранично-скелетная модель дискретного изображения с контролируемой точностью аппроксимации	367
<i>А.А. Морозов</i> Логическое программирование агентов для поиска и распознавания информации в Интернет	371
<i>С.А. Мустафин</i> Об одном методе построения скелетов объектов изображения	374
<i>А.Ф. Мухамедгалиев, А.А. Мухамедгалиев</i> Геоинформационные технологии в задачах обновления цифровых картографических данных	376
<i>Т.В. Мухина, И.Ю. Зарайская, К.В. Анохин</i> Отслеживание движений животных с использованием 2D модели	378
<i>А.А. Нижегородов, А.В. Шолохов</i> Идентификация отказов измерительных модулей на основе функционального резервирования датчиков	381
<i>А.В. Никоноров, С.Б. Попов, В.А. Фурсов</i> Идентификация нелинейных моделей цветовоспроизведения	384
<i>А.Х. Нишанов, Ш.Е. Туляганов, О.Ж. Бобомуродов, М.Х. Худайбердиев</i> Распознавание и адаптация для дистанционного образования	387
<i>Н.А. Новоселова, Б.А. Залесский, О.В. Красько, Н.М. Скриган, Е.Е. Сотикова, А.П. Сучкова, И.Э. Том</i> Компьютерная подсистема для статистической и интеллектуального анализа медицинских данных	389
<i>М.М. Ольшевец, М.Н. Устинин, И.А. Никонов</i> Программный комплекс для медицинской цифровой рентгенографии	392
<i>В.Ю. Павлов, В.Н. Сергеева, А.В. Тьков, Т.О. Железнякова</i> Автоматизированное выделение объектов байкальских диатомей на РЭМ – снимках донных осадков	394
<i>Н.М. Панкратова, М.Н. Устинин, А.М. Молчанов</i> Моделирование переключения режимов биомагнитной активности мозга	398
<i>И.В. Покровская, Е.В. Бауман, А.А. Дорофеев, А.Л. Чернявский</i> Методы регионального управления на базе алгоритмов экспертного и классификационного анализа	401
<i>И.В. Покровская, А.А. Дорофеев</i> Классификационные и экспертные методы в задаче определения оптимальных ставок налогов	404

<i>В.Н. Попов</i> Диагностика структурных изменений в датчиках информационно – измерительных систем	407
<i>Н.В. Попова</i> Использование информационных технологий для решения проблем малого и среднего бизнеса: структурный подход	409
<i>Р.В. Поцеваев, И.Б. Петров</i> Восстановление траекторий движения пера по изображениям рукописных символов	412
<i>Ю.П. Пытьев, А.И. Чуличков</i> Морфологический анализ изображений: сравнение по форме, узнавание, классификация, оценка параметров	415
<i>С.С. Раджабов</i> Об одном методе распознавания символов на карте	418
<i>В.Е. Романов</i> Ориентирующие базы данных для совершенствования решения технологических задач	419
<i>В.Е. Романов, Л.Т. Жукова, Р.Р. Саакян</i> Применение методов теории распознавания образов для прогнозирования свойств легированных сплавов и сталей	423
<i>В.Е. Романов, И.В. Фоменко, А.П. Жабко, А.М. Киселев</i> Применение методов распознавания образов для прогнозирования свойств и характеристик объектов обработки в двухфазных многокомпонентных диффузионных средах	425
<i>В.Е. Романов, И.В. Фоменко, И.А. Мелентьева</i> Компьютерное обучение как трудно формализуемая задача	427
<i>Р.Р. Саакян, Н.К. Жиганов, И.А. Шпехт</i> Сочетание регулярных и эвристических подходов в прогнозировании свойств химических нитей в поле технологических факторов	430
<i>Р.Р. Саакян, Е.Г. Маежов, В.В. Сигачева, С.Н. Бобрышев</i> Алгоритм классификации химических нитей на основе аналитических представлений зависимостей свойств нити от факторов формования	433
<i>С.Ю. Сергунин, К.М. Квашинин, М.И. Кумсков</i> Схема динамического построения многоуровневого описания изображений	436
<i>О.С. Середин, А.В. Скоркин</i> Процедура парного элайнмента для автоматического оценивания качества систем оптического распознавания текста	439

<i>Ю.Г. Сосулин, Фам Чунг Зунг</i> Метод нейросетевого формирования инвариантных к повороту признаков для распознавания двумерных изображений.....	443
<i>В.В. Сычев, М.Н. Устинин</i> Программный комплекс MRIAN для обработки МЭГ головного мозга и локализации дипольных источников магнитного поля на МРТ	447
<i>В.С. Терещенко, В.Е. Анциперов</i> Быстрые алгоритмы выделения графических примитивов в задачах распознавания и сжатия контурных изображений	450
<i>А.А. Тихонов</i> Интегральные оценки исправности сложных систем по их обобщённым характеристикам	451
<i>В.Л. Токарев, А.О. Гирлин, М.Ф. Садыков</i> Восстановление изображений с недостаточно определенным контуром	453
<i>И.Э. Том, О.В. Красько, М.П. Потапов, Т.А. Углова</i> Анализ прогностических факторов риска в детской онкогематологии	455
<i>А.Т. Трофимов, В.А. Колядинцев, А.Е. Николаев</i> Синтез полигауссовских алгоритмов обработки большеформатных полутонных изображений	458
<i>Ш.Е. Туляганов, О.Ж. Бобомуродов, М.Х. Худайбердиев</i> Функциональная модель интеллектуального электронного пособия.....	461
<i>Д.М. Устинин, А.И. Чуличков</i> Измерение наноструктур методом морфологического анализа изображений	463
<i>Ш.Х. Фазылов, М.Т. Тухтасинов</i> Об одной алгоритмической схеме решения задачи распознавания лиц.....	464
<i>Н.Г. Федотов, Т.В. Никифорова</i> Методы предварительной обработки изображений на основе Тгасе- преобразования	466
<i>Я.А. Фурман</i> Кватернионный анализ изображений	469
<i>Р.Г. Хафизов</i> Распознавание кватернионных сигналов на основе их представления в собственной системе отсчета	471
<i>Г.В. Цепков, А.В. Лефтеров</i> Имитатор сетчатки глаза для визуальной коммуникации	473
<i>Д.А. Цымбал, Г.М. Емельянов, Д.В. Разумов</i> Алгоритм текстурной сегментации с помощью раскрашенной карты Кохонена и фильтров Габора	476
	509

<i>Е.А. Черёмухин, А.И. Чуличков</i>	
Об одном алгоритме восстановления изображений по проекциям	481
<i>М.А. Чичева, Н.И. Глумов, В.В. Сергеев</i>	
Оптимизация процедуры линейной фильтрации в прикладных задачах обработки изображений	482
<i>В.Я. Чучупал, К.А. Маковкин., А.В. Чичагов</i>	
Адаптация к голосу и среде в системе распознавания речи	485
<i>А.В. Шолохов</i>	
Формирование траекторий из участков сети возможных траекторий.....	488
<i>А.М. Шурыгин, М.С. Стригунова</i>	
Прогноз сильных землетрясений в линейных зонах	491
<i>В.Н. Юдин</i>	
Анализ данных и извлечение знаний с помощью Универсального Классификатора.....	494

Научное издание

ДОКЛАДЫ XI ВСЕРОССИЙСКОЙ КОНФЕРЕНЦИИ
**МАТЕМАТИЧЕСКИЕ МЕТОДЫ РАСПОЗНАВАНИЯ
ОБРАЗОВ**

Подписано в печать 7.10.2003 г. Формат 60x90/16.
Бумага офсетная. Печать офсетная.
Усл.печ.л. 17. Тираж 1000 экз. Заказ 4815. Изд. № 94

г.Москва, ул. Складочная, 1, стр. 17
ООО "Регион-Холдинг"