

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

**МАТЕМАТИЧЕСКИЕ МЕТОДЫ
РАСПОЗНАВАНИЯ ОБРАЗОВ**

ММРО-12

Доклады 12-й Всероссийской конференции

Москва
2005

Аннотация

В сборнике представлены доклады 12-й Всероссийской конференции «Математические методы распознавания образов», проводимой Вычислительным центром им. А.А. Дородницына Российской академии наук при финансовой и организационной поддержке РФФИ (грант № 05-01-10142) и компании Foresys.

Конференция регулярно проводится один раз в два года, начиная с 1983 г., и является самым представительным российским научным форумом в области распознавания образов, интеллектуального анализа данных и прогнозирования.

Оргкомитет

Председатель: Журавлев Юрий Иванович, *академик РАН*
Зам. председателя: 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.*
Местецкий Леонид Моисеевич, *д.т.н.*
Немирко Анатолий Павлович, *д.ф.-м.н.*
Устинин Михаил Николаевич, *к.ф.-м.н.*
Песков Николай Владимирович, *к.ф.-м.н.*
Рейер Иван Александрович, *к.т.н.*

Программный оргкомитет

Председатель: Рудаков Константин Владимирович, *член-корр. РАН*
Зам. председателя: Матросов Виктор Леонидович, *член-корр. РАН*
Ученый секретарь: Чехович Юрий Викторович, *к.ф.-м.н.*
Члены: Микаэлян Андрей Леонович, *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: Вальков Антон Сергеевич, *к.ф.-м.н.*
Ефимов Александр Николаевич
Ивахненко Андрей Александрович
Инякин Андрей Сергеевич
Кирсанов Антон Андреевич
Кочедыков Денис Алексеевич
Никитов Глеб Владимирович

I. Математическая теория распознавания

Сложность алгоритмов решения задачи синтеза групповых классификаций

М.Б. Айдарханов, Е.Н. Амиргалиев

(Алматы)

Пусть задано конечное множество объектов $M = \{S_1, \dots, S_n\}$ из некоторого объектного множества D . Для каждого S_i определено $J(S_i)$ - описание объекта. Задача классификации Z_k состоит в следующем. Для множества объектов M по информации $J(M)$ найти классы эквивалентных объектов $K_1(M), \dots, K_2(M)$ то есть классификацию $K(M)$.

Рассмотрим задачу синтеза групповой классификации Z_c .

Пусть $A_1, \dots, A_m \in \{A\}$ - исходный набор алгоритмов решения задачи классификации Z_k для множества объектов $M = \{S_1, \dots, S_n\}$.

Результатом применения алгоритмов A_i к $(M, J(M))$ являются классификации $K_i(M) \in \mathfrak{R}(M)$, где $\mathfrak{R}(M)$ - пространство классификаций конечного множества объектов M . Пусть определена метрика $d(K', K'')$ в $\mathfrak{R}(M)$ и

$$\varphi(K) = \sum_{i=1}^m d(K, K_i), \quad K_i = K_i(M), \quad K \in \mathfrak{R}(M). \quad (1)$$

Задача Z_c : Найти $K^*(M) \in \mathfrak{R}(M)$, минимизирующую функционал

$$\varphi(K^*) = \min \varphi(K), \quad K \in \mathfrak{R}(M). \quad (2)$$

Для построения алгоритмов решения задачи синтеза групповых классификаций будут использоваться решения следующих двух вспомогательных легко решаемых задач Z_1 и Z_2 .

Задача Z_1 . Данная задача состоит в построении результирующего бинарного отношения R с использованием критерия большинства для представлений исходных классификаций K_1, \dots, K_m в виде матриц соответствующих им отношений эквивалентностей R_1, \dots, R_m .

Задача Z_2 . Задача сводится к минимизации функционала

$$\varphi_1(K_i(l_i)) = \sum_{v=1}^m d(K_v(l_v), K_i(l_i)), \quad (3)$$

в результате которой находится оптимальная классификация $K_i(l_i)$ в пространстве классификации, удовлетворяющая условию

$$\varphi_1(K_i(l_i)) = \min_{K_i(l_i) \in \tilde{K}(M)} \varphi_1(K_i(l_i)). \quad (4)$$

Рассмотрим задачу Z_c . Представляет интерес отдельный анализ этой задачи при $l_1 = \dots = l_m = l$ и при произвольных $l_v, 1 \leq l_v \leq n, v = 1, \dots, m$.

Пусть $l_1 = l_2 = \dots = l_m = l$. Требуется найти классификацию $K_n^* \in K^l(M)$, где $K^l(M)$ множество всех классификаций M содержащих l классов, удовлетворяющую условию

$$\varphi(K_n^*) = \min_{K_n \in K^l(M)} \sum_{v=1}^m d(K_n^v(l), K_n). \quad (5)$$

Приведем локально-экстремальные алгоритмы решения этой задачи.

Алгоритм A^1 .

Шаг 0. (выбор начального приближения). Решается задача Z_2 . Решение этой задачи – классификация K^0 принимается за начальное приближение. Запоминается значение $\varphi_1(K^0) = \varphi(K^0)$.

Шаг 1. Строится 2-окрестность $B_2^l(K^0)$ объекта K^0 и для каждого объекта $K_i^0 \in B_2^l(K^0)$ вычисляется значение $\varphi(K_i^0)$. Если $\varphi(K_i^0) \geq \varphi(K^0)$ для всех $K_i^0 \in B_2^l(K^0)$, то алгоритм заканчивает работу и K^0 - искомое решение локально-экстремальной задачи. Если для $K_{i_v}^0, v = 1, \dots, r, \varphi(K_{i_v}^0) < \varphi(K^0)$, то находится $\min\{\varphi(K_{i_1}^0), \dots, \varphi(K_{i_r}^0)\} = \varphi(K^1)$, фиксируется классификация K^1 .

Шаг 2. В силу теоремы 2.2 из [1] классификация K^1 построена из классификации K^0 переносом некоторого объекта S_0 из класса с номером u в класс с номером w . Теперь построим $B_2^l(K^1)$, начиная последовательный поочередный перенос объектов из класса с номером w ,

т.е. K^{1w} , в классы с номерами $1, 2, \dots, w-1, w+1, \dots, l$. Очевидно, что при переносе S_0 в K^{1u} получится классификация K^0 , а при переносе S_0 в остальные классы K^l получаются некоторые классификации из анализируемого множества $B_2^l(K^0)$. Поэтому объект S_0 фиксируется в классе K^{1w} . В силу теорем 2.2 и 2.4 из [1, 2], $B_2^l(K^l) \cup B_2^l(K^0) \subset B_1^l(K^0)$, т.е. осуществляется направленный поиск.

Вычисляя $\varphi(K_i^l)$ для $K_i^l \in B_2^l(K^1)$ фиксируем классификацию. На некотором шаге $(p+1)$ находится классификация K^p такая, что $\varphi(K^p) \leq \varphi(K_i^p)$, для всех $K_i^p \in B_2^l(K^p)$.

Алгоритм A^2 . Решаются задачи Z_2 и Z_1 . Вычисляется значение $\rho(K^0, R)$, где K^0 - решение задачи Z_2 , R - результирующее бинарное отношение, соответствующее решению задачи Z_1 . Анализируется окрестность $B_2^l(K^0)$ и $\rho(K_i^0, R)$ для всех $K_i^0 \in B_2^l(K^0)$.

Теорема 1. Сложность $C(A^1)$ алгоритма A^1 есть $O(n^5 m)$.

Теорема 2. Сложность $C(A^2)$ алгоритма A^2 есть $C(A^2) = O(n^2(n^9 + m))$.

Доказательства теорем рассмотрены в [3].

Таким образом, оценена сложность алгоритмов решения задачи синтеза групповой классификации. Для предложенных алгоритмов A^1, A^2 , эта сложность полиномиальная. Максимальная степень полинома не превышает шестой степени, причем пятой степени по отношению к мощности множества M , равной n и первой степени по отношению к количеству исходных алгоритмов классификации, равному m . Этим подтверждается возможность реального использования алгоритмов при решении задачи синтеза групповой классификации Z_c .

Литература

1. Айдарханов М.Б. Метрический и структурный подходы к построению групповых классификаций. – Алматы: Гылым, 1994. – 56 с.
2. Aidarkhanov M.B. Metric and Structural Approaches to the Construction of Group Classifications. – Pattern Recognition and Image Analysis, Vol.4, N 4, 1994, pp.372 – 389.
3. Айдарханов М.Б., Амиргалиев Е.Н. Исследование сложности решения синтеза групповых решений в пространстве классификаций //

Обобщенное расстояние евклида-махаланобиса и его применение в задачах распознавания образов

С.А. Амелькин, В.М. Хачумов

(Переславль-Залесский)

Одной из задач решаемых в процессе распознавания образов, является определение расстояния от точки, координаты которой представляют собой параметры наблюдаемого объекта, до класса n сходных объектов. Для этого пользуются метриками Евклида и Махаланобиса. Каждая из этих метрик имеет свои преимущества и недостатки.

Метрика Евклида, используемая для определения расстояния между точками, x_1, x_2

$$R_E^2(x_1, x_2) = (x_1 - x_2)^T \cdot (x_1 - x_2) \quad (1)$$

удовлетворяет всем аксиомам расстояния, она удобна для определения расстояния между двумя точками, например, между точкой наблюдаемых параметров и центром (выборочным средним) класса. Она не учитывает распределение точек в классе.

Метрика Махаланобиса описывается, как

$$R_M^2(x, X) = (x - \bar{x})^T C^{-1} (x - \bar{x}), \quad (2)$$

где \bar{x} – выборочное среднее класса X . Она представляет собой квадратичную форму, где C^{-1} – матрица, обратная корреляционной для рассматриваемого класса.

Метрика Махаланобиса неприменима, если выборочная дисперсия хотя бы одного из параметров равна нулю:

$$\lim_{D_i \rightarrow 0} R_M^2(x, X) = \infty. \quad (3)$$

Метрика Махаланобиса совпадает с Евклидовой в случае, если класс представляет собой вектор реализаций нормированных (дисперсии $D_i=1$, $i=1, \dots, n$) независимых (ковариации $K_{ij}=0$, $i, j=1, \dots, n$, $i \neq j$) случайных величин. Если дисперсии больше 1, то расстояние Махаланобиса меньше Евклидова, если меньше, то $R_M^2 > R_E^2$. Проверка аксиом расстояния затруднена тем, что метрика используется для определения расстояния между разнородными объектами. Расстояние между двумя точками

согласно (3) почти всегда бесконечно велико. Исключением является случай, рассмотренный в приложении, который можно считать доказательством, что $R_M^2(x, x) \neq 0$. Метрику Евклида можно, как и метрику Махаланобиса, представить в виде квадратичной формы, матрицей которой является единичная матрица:

$$R_E^2(x_1, x_2) = (x_1 - x_2)^T E(x_1 - x_2) \quad (4)$$

Метрика Махаланобиса может также использоваться и для измерения расстояния между двумя классами X_1 и X_2 . Для этого используют среднее взвешенное расстояний Махаланобиса от выборочных средних:

$$\tilde{R}_M^2(X_1, X_2) = \gamma R_M^2(\bar{x}_1, X_2) + (1 - \gamma) R_M^2(\bar{x}_2, X_1). \quad (5)$$

Такая метрика неудобна, т.к. если класс X_1 состоит из единственной точки x_1 , то $\tilde{R}_M^2(x_1, X_2) \neq R_M^2(x_1, X_2)$. Рассмотрим обобщенную метрику Евклида - Махаланобиса, определяющую расстояние между двумя классами X_1 и X_2 , в виде квадратичной формы

$$R_G^2(X_1, X_2) = (\bar{x}_1 - \bar{x}_2)^T A^{-1}(\bar{x}_1 - \bar{x}_2), \quad (6)$$

где \bar{x}_1 и \bar{x}_2 - средние выборочные классов, матрица A^{-1} является обратной матрицей произведения

$$A = (C_1 + E)(C_2 + E), \quad (7)$$

C_1 и C_2 - корреляционные матрицы для первого и второго классов соответственно. Для любых двух классов X_1 и X_2 у которых $\bar{x}_1 = \bar{x}_2$, расстояние $R_G^2(X_1, X_2) = 0$. Если класс X_1 представляет собой точку, то соответствующая ему корреляционная матрица состоит из нулей и мы получаем расстояние, аналогичное расстоянию Махаланобиса, с той разницей, что $R_G^2(x_1, X_2) = R_E^2(x_1, \bar{x}_2)$ в случае если дисперсия $D_i = 0$, ($i=1, \dots, n$). Если оба класса представляют собой точки, то $R_G^2(x_1, x_2) = R_E^2(x_1, x_2)$. Такая метрика удобна для решения задач

распознавания образов, в которых некоторые параметры, описывающие наблюдаемые объекты, не изменяются. Рассмотрим, в качестве примера, задачу классификации летательных аппаратов [1]. В табл.1 приведены характерные размеры некоторых отечественных самолетов, взятые из открытых источников. Данные по размаху крыльев самолетов Су

практически одинаковы. Из-за того, что дисперсия размаха крыльев мала, расстояние Махаланобиса от некоторой точки до класса Су очень велико. В результате получаем неприемлемый ответ.

Табл. 1. Характерные размеры некоторых отечественных самолетов

Модель самолета	Длина самолета (м)	Размах крыльев (м)	Высота (м)
Миг-23	16,7	13,46	5,15
Миг-25	19,75	14,015	5,139
Миг-27	17,1	14	6
Миг-29	17,32	11,36	4,73
Миг-31	22,69	13,46	5,15
Су-27	21,935	14,7	5,932
Су-30	21,94	14,7	6,36
Су-32	22	14,7	5,93
Су-33	21,19	14,7	5,93
Су-35	22,18	14,7	6,35
Су-37	22,183	14,698	6,433
Су-39	21,9	14,7	5,9

Расстояние Евклида не учитывает корреляционных зависимостей в классах, поэтому оно также приводит к ошибкам. Расстояние $R_G^2(x, X)$ свободно от указанных выше недостатков, что позволяет правильно идентифицировать объект. Таким образом, методы измерения расстояния с использованием метрики Махаланобиса непригодны в случае, когда значение хотя бы одного элемента на главной диагонали корреляционной матрицы, описывающей класс, достаточно мало, то есть, когда дисперсия какого-либо показателя мала. При этом расстояние Махаланобиса оказывается неоправданно велико. Предложенная метрика, учитывает корреляционные свойства классов, таким образом, что расстояние между точкой и классом стремится к расстоянию Евклида когда дисперсии параметров класса стремятся к нулю.

Работа поддержана грантом РФФИ № 03-01-00808.

Литература

1. Пережигин А.А., Хачумов В.М. Обнаружение и автоматическое определение параметров летательного объекта на видео потоке. - Информационные технологии и вычислительные системы, № 1, 2005, с. 38-48.

Метод коротких корреляционных функций в задачах структурирования сигналов сложной природы

В.Е. Анциперов
(Москва)

Институт радиотехники и электроники РАН (www.cplire.ru)

В докладе излагаются результаты исследования динамики параметров коротких корреляционных функций случайных, хаотических сигналов. В центре внимания находится проблема определения участков квазипериодического поведения этих сигналов и моменты смены колебательных режимов. Определяются связанные с корреляционными функциями количественные характеристики типа степени корреляции, основной частоты и т.д. На основе временной зависимости боковых максимумов корреляционных функций построены инструментальные оценки параметров степени квазипериодичности, длительности участков квазипериодичности, периода основного тона и т.д. Подобный анализ заданной реализации случайного процесса позволяет сформировать его целостный образ и на его основе судить о поведении источника сигнала в терминах его динамики – для динамических систем, в терминах текстурного состава для изображений, в терминах передаваемой информации в случае хаотического кодирования. В докладе приведены результаты экспериментального применения рассматриваемой методологии к сигналам биологической природы – речевым сигналам и балистокардиографическим данным.

Основы методологии

Участки квазипериодического поведения сигнала определим таким образом, что в их пределах реализация $S(t)$ может быть представлена (по аналогии с квазигармоническим сигналом) в форме:

$$(1) \quad S(t) = A(t)F\left(\frac{t}{T} + \varphi(t)\right),$$

где $F[\dots]$ – периодическое, с периодом 1, продолжение произвольной, заданной на интервале $[0,1]$ формы колебаний $F[x]$:

$$(2) \quad F(x+k) = F(x) \quad k = 0, \pm 1, \pm 2, \dots,$$

T – период, $A(t)$ и $\varphi(t)$ – медленно меняющиеся на периоде T амплитуда и фаза, обуславливающие отличие сигнала от строго периодического.

Выделим при помощи взвешивающего окна $\Delta(t)$ - симметричной функции длительности $\sim T_\Delta$, $\Delta(\pm\infty)=0$ два близких фрагмента сигнала $S_1(t)$ и $S_2(t)$ соответствующих моментам времени t_1 и t_2 соответственно:

$$S_1(t) = \Delta(t-t_1)S(t), \quad S_2(t) = \Delta(t-t_2)S(t).$$

Совместим оба фрагмента в начале координат и в качестве меры их подобия возьмем скалярное произведение нормированных версий:

$$(3) \quad R(t, \tau) = \frac{\int_{-\infty}^{\infty} S_1(t'+t_1)S_2(t'+t_2)dt'}{\sqrt{\int_{-\infty}^{\infty} S_1^2(t')dt'} \sqrt{\int_{-\infty}^{\infty} S_2^2(t')dt'}}$$

где $t = (t_2 + t_1)/2$ – анализируемый момент времени, $\tau = (t_2 - t_1)$.

Короткая корреляционная функция (ККФ) $R(t, \tau)$ (3) по структуре подобна нормированным автокорреляционным функциям (АКФ) стационарных сигналов, но в общем случае зависит от времени t . Легко показать, что как и АКФ она всегда имеет по τ в нуле единичный максимум. Если бы сигнал $S(t)$ был строго периодичен, то, в силу (2) периодичной по τ была бы и $R(t, \tau)$, т.е. имела бы единичные боковые максимумы при $\tau = \pm T, \pm 2T$ и т.д. В случае нестрогой периодичности (квазипериодичности) боковые максимумы понижаются и, оказывается, что их величины (в особенности у первых максимумов при $\tau = \pm T$) оказываются исключительно полезными для анализа поведения сигнала.

Подробный анализ зависимости $R(t, \tau)$ (3) от факторов $A(t)$, $\varphi(t)$ и $\Delta(t)$ приводит к следующим результатам. В предположении $T_{\Delta} > T_A > T$, где T_A – характерное время огибающей $A(t)$, $R(t, \tau)$ факторизуется к виду:

$$(4) \quad R(t, \tau) = R_0(\tau)\eta(t, \tau),$$

где $R_0(\tau)$ – АКФ строго периодического сигнала $F(t)$ и $\eta(t, \tau)$ – ККФ медленно меняющейся амплитуды $A(t)$. Рис.1 иллюстрирует эффект уменьшения основных максимумов $R_0(\tau)$ за счет нестационарности, обусловленной изменяющейся амплитудой:

Искажающий фактор $\eta(t, \tau)$ (4) при небольших τ , например, $\tau \sim T$ приобретает вид параболы:

$$(5) \quad \eta(t, \tau) \approx 1 - \frac{1}{2} \left(\frac{n(t)}{T_{\Delta}} \right)^2 \tau^2,$$

где параметр $n(t)$ связан с вариабельностью огибающей $A(t)$ и имеет смысл числа ее «осцилляций» на анализируемом участке длительности T_{Δ} : его малые значения характеризуют фрагмент сигнала как периодический, большие $\sim T_{\Delta}/T$ – как, с точки зрения периодичности, безструктурный.

Замечательной особенностью $n(t)$ является то, что он легко находится по ККФ $R(t, \tau)$ (3): в соответствии с (4) и (5) этот параметр равен величине первого бокового максимума (при $\tau = T$):

$$(6) \quad n(t) \approx \sqrt{2[1 - R(t, T_M)]} \frac{T_\Delta}{T_M},$$

где T_M - положение бокового максимума – основной период колебаний.

Экспериментальные результаты

Динамика нормированного к единице параметра $n(t)$ исследовалась применительно к сигналам сложной природы – речевым сигналам и балистокардиографическим записям. На Рис.2 и Рис.3 приведены соответствующие примеры:




Рис. 1. Эффект уменьшения основных максимумов $R_0(\tau)$ за счет нестационарности, обусловленной изменяющейся амплитудой.




Рис. 2. Минимумы в динамике $n(t)$ обусловлены вокализованными «Н», «О», «Л» в слове «НОЛЬ», имеющими выраженную периодическую структуру.




Рис.3. Максимумы в записи соответствуют неконтролируемым движениям пациента, минимумы – периодическим колебаниям сердца.

Литература

1. Antsiperov W.E., Morozov V.A., // J. Communications Technology and Electronics, 49 (12), 2004, p 1333-1341.
2. Antsiperov W.E., Morozov W.A., Nikitov S.A. // Pattern Recognition and Image Analysis, 2005, (to be printed).

Использование метода статистических испытаний в определении мод гауссовой смеси

Н.Н. Апраушева, В.К. Де Ванса Викрамаратне, С.В. Сорокин
(Москва)

Предлагаемый алгоритм отыскания мод базируется на принципе внутренней экстремальной точки, состоящем в следующем. Если функция $f(x)$ определена и непрерывна вместе со своей производной $f'_x(x)$ на отрезке $[a, b]$, то для любой точки $x \in [a, b]$ существует отрезок $[\alpha_x, \beta_x]$ длины λ_x , $x \in [\alpha_x, \beta_x] \subset [a, b]$, в котором функция $f(x)$ или строго монотонна, или не монотонна и имеет только одну экстремальную точку $x_e \in (\alpha_x, \beta_x)$.

Исследовалась гауссова смесь с плотностью вероятности

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

где $2 \leq k < \infty$, $x \in (-\infty, \infty)$, μ_i — математическое ожидание i -й компоненты, π_i — её априорная вероятность, σ^2 — дисперсия каждой компоненты,

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

Параметры распределения в (1) известны, для определённости положим

$$\mu_1 < \mu_2 < \dots < \mu_k. \quad (2)$$

Моды обозначим через

$$\hat{x}_1, \hat{x}_2, \dots, \hat{x}_m, \quad 1 \leq m \leq k.$$

Предположим, что для каждой точки μ_i , $i=1, 2, \dots, k$, известна длина отрезка λ_{μ_i} , удовлетворяющего принципу внутренней экстремальной точки.

Фиксируем ту S -ю компоненту смеси, которая имеет наибольшую априорную вероятность π_S и исследуем δ -окрестность её среднего значения μ_S , где $\delta = 2^{-1} \lambda_{\mu_S}$. На отрезке $[\mu_S - \delta, \mu_S + \delta]$ моделируем n , $n \geq 10$, случайных равномерно распределённых чисел

$$\xi_1^{(1)}, \xi_2^{(1)}, \dots, \xi_n^{(1)}$$

и определяем значения $f(\xi_i^{(1)})$, $i = 1, 2, \dots, n$,

$$\xi_1 = \arg \max_i f(\xi_i^{(1)}).$$

1. Если

$$f(\xi_1) > f(\mu_S - \delta), \quad f(\xi_1) > f(\mu_S + \delta), \quad (3)$$

то первая мода найдена, $\hat{x}_1 = \xi_1$.

2. Если в (3) не выполняется хотя бы одно из неравенств, например второе, то исследуем отрезок $[\mu_S + \delta, \mu_S + 2\delta]$, в котором моделируем n случайных равномерно распределённых чисел

$$\xi_1^{(2)}, \xi_2^{(2)}, \dots, \xi_n^{(2)}.$$

Находим значения $f(\xi_i^{(2)})$, $i = 1, 2, \dots, n$,

$$\xi_2 = \arg \max_i f(\xi_i^{(2)}).$$

Если

$$f(\xi_2) > f(\mu_S + \delta), \quad f(\xi_2) > f(\mu_S + 2\delta),$$

то $\hat{x}_1 = \xi_2$.

Если

$$f(\mu_1 + \delta) > f(\xi_2),$$

то $\hat{x}_1 = \mu_1 + \delta$.

Если

$$f(\mu_1 + 2\delta) > f(\xi_2),$$

то исследуем отрезок $[\mu_1 + 2\delta, \mu_1 + 3\delta]$ и т.д., пока на t -м шаге не найдём внутреннюю максимальную точку x_e отрезка $[\mu_S - \delta, \mu_S + t\delta]$, $t = 1, 2, \dots$. Тогда $\hat{x}_1 = x_e$. Все точки μ_i , $i \in \{1, 2, \dots, k\}$, лежащие в

полуинтервале $[\mu_s - \delta, \mu_s + t\delta)$ исключаются из рассмотрения.

Если множество (2) не пусто, то из оставшихся компонент смеси фиксируем ту, которая имеет наибольшую априорную вероятность, и для её среднего значения повторяем всё вышеописанное исследование.

На основании теоретических результатов [1, 2] можно положить

$$\delta = 4^{-1} \sqrt{2} \sigma. \quad (4)$$

Результаты экспериментов показали, что если $\rho_{i,i+1} \geq 3$ ($\rho_{i,i+1}$ - расстояние Махаланобиса между i -й и $(i+1)$ -й компонентами смеси), то принцип внутренней экстремальной точки имеет место при δ , определённом в (4).

Но возможны случаи, когда отрезок длины 2δ имеет более одной экстремальной точки. Например, функция $f(x)$ смеси с параметрами $k = 2$, $\mu_1 = 0$, $\mu_2 = 2.01$, $\sigma = 1$, $\pi_1 = \pi_2 = 0.5$, на отрезке $[0; 0.707]$ не имеет ни одной экстремальной точки, а на отрезке $[0.707; 1.414]$ имеет три внутренние экстремальные точки (две моды $\hat{x}_1 = 0.830$, $\hat{x}_2 = 1.175$ и один локальный минимум $\check{x} = 1.005$). Наш алгоритм найдёт одну моду, например \hat{x}_1 . Для определения другой моды исследуются отдельно отрезки $[0.707; \hat{x}_1]$ и $[\hat{x}_1; 1.414]$.

Если для смеси выполняется одно из условий унимодальности [2, 3], то исследование проводится для её математического ожидания.

Наш алгоритм определяет макромоды, но может пропустить некоторые микромоды, как и другие алгоритмы, основанные на градиентном подъёме. Так, для смеси с параметрами $k = 4$; $\sigma = 1$; $\mu_1 = 0$; $\mu_2 = 2.5$; $\mu_3 = 4.44$; $\mu_4 = 6.94$; $\pi_1 = 0.365$; $\pi_2 = 0.135$; $\pi_3 = 0.135$; $\pi_4 = 0.365$ находятся макромоды $\hat{x}_1 = 0.045$; $\hat{x}_4 = 6.895$ и пропускаются микромоды $\hat{x}_2 = 2.635$; $\hat{x}_3 = 4.305$. Для преодоления этого недостатка предлагаем использовать описанный алгоритм в сочетании с алгоритмом, основанном на методе Пикара и описанном в [1].

Литература

1. Апрашева Н.Н., Моллаверди Н. и др. О модах гауссовой смеси. М.: ВЦ РАН, 2003.
2. Aprausheva N.N., Sorokin S.V. On the unimodality of the Simple Gaussian mixture. *Juor. Comput. Mathematics and Mathemat. Physics*, Vol.44, No.5, 2004, 785-793.
3. Aprausheva N.N., Mollaverdi N. and Sorokin S.V. Boundaries for the

Number of the Simple Gaussian Mixture Modes. Pattern recognition and image analysis, 2005. V.15. N.1. P.2004-2006.

Нейросетевые алгоритмы распознавания с логической коррекцией

*Л.А. Асланян, Л.Ф. Минго, Х.Б. Кастелянос, В.В. Рязанов,
Ф.Б. Челноков*

(Ереван, Мадрид, Москва)

Математическая теория распознавания имеет богатую историю и разнообразие форм моделирования реального мира. Тематика исследований различных исследовательских групп обычно тесно связана с определенной областью математики и традициями соответствующих организаций. Обычно выделяют и различают функциональные и алгоритмические подходы. Нейронные сети (например) аппроксимируют выходную функцию, но при этом параметры модели не имеют адекватной интерпретации. Алгоритмические модели (например, алгоритмы вычисления оценок) предоставляют интерпретируемые параметры, хотя могут иметь большую вычислительную сложность. Объединение научных школ и групп «узких специалистов» в рамках единых проектов несомненно дает возможность более полного раскрытия потенциала отдельных подходов и алгоритмов, и их интеграции. Создание одного подобного объединения связано с выполнением цикла проектов ИНТАС группами исследователей из России, Испании, Армении и некоторых других стран.

В Вычислительном центре им А. А. Дородницына РАН на протяжении 35 лет под руководством академика РАН Ю. И. Журавлева проводятся интенсивные исследования по алгебраической теории алгоритмов распознавания с использованием (в качестве основного) аппарата дискретного анализа и алгебры [1]. Исследования Института информатики и проблем автоматизации Национальной Академии наук Армении проводятся в рамках тех же дискретных моделей распознавания. Здесь проблемы обучения и распознавания образов базируются на использовании оптимизационных структур дискретной изопериметрической задачи, дискретной томографии и на иерархическом поиске классов [2]. Исследования Мадридского политехнического университета лежат в русле нейросетевых моделей, прежде всего с использованием полиномиальных функций выхода и линейных активационных функций [3]. Исследовались возможности временных задержек сигналов для решения задач прогнозирования, при этом получены высокие результаты при прогнозировании торговли на фондовой бирже и на других аналогичных задачах.

В рамках проектов Интас 96-952, 00-397 и 00-626 указанными

группами были созданы некоторые гибридные модели и прикладные программы для решения задач распознавания. Одна из совместных разработок основана на склеивании нейросетевых алгоритмов распознавания и логических схем коррекции распознающих алгоритмов. Основным мотивом данного исследования было создание такого программного продукта для решения задач распознавания и прогноза, который не требовал бы вмешательства пользователя в процесс обучения, или такое вмешательство было бы минимальным и не требующим специальных знаний. Разработанная в итоге программа NNLC (при поддержке гранта ИНТАС 03-56-182 инно) в значительной степени оправдала соответствующие ожидания. Она продемонстрировала высокие и стабильные по точности результаты распознавания на многих тестовых практических задачах.

Опишем общую схему обучения и распознавания в задачах с l классами (следуя обозначениям [1]). Пусть заданы обучающая S_1, S_2, \dots, S_m и контрольная S'_1, S'_2, \dots, S'_q выборки. Для простоты считаем, что задача распознавания решается «без отказов»,

$$S_{m_{i-1}+1}, S_{m_{i-1}+2}, \dots, S_{m_i} \in K_i, i = 1, 2, \dots, l, m_0 = 1, m_l = m,$$

$$S'_{q_{i-1}+1}, S'_{q_{i-1}+2}, \dots, S'_{q_i} \in K_i, i = 1, 2, \dots, l, q_0 = 1, q_l = q.$$

Пусть по обучающей выборке построено N нейросетевых алгоритмов распознавания $A_j(S) = (\alpha_1^j(S), \alpha_2^j(S), \dots, \alpha_l^j(S))$,

$\alpha_i^j(S) \in \{0, 1\}, i = 1, 2, \dots, l, j = 1, 2, \dots, N$. Применяя их к объектам контрольной выборки мы получим следующую матрицу результатов распознавания:

$$A_j(S'_t) = (\alpha_1^j(S'_t), \alpha_2^j(S'_t), \dots, \alpha_l^j(S'_t)),$$

$$\alpha_i^j(S'_t) \in \{0, 1\}, i = 1, 2, \dots, l, j = 1, 2, \dots, N, t = 1, 2, \dots, q.$$

Алгоритм распознавания коллективом нейронных сетей сконструируем по принципу потенциальной коррекции [4]. Классификация произвольного нового объекта осуществляется путем отнесения объекта в класс, за который он имеет максимальную оценку, причем оценки вычисляются

следующим образом: $\Gamma_i(S) = \frac{1}{q_j - q_{j-1}} \sum_{t=q_{j-1}+1}^{q_j} \Phi_i(S'_t, S), i = 1, 2, \dots, l$.

Величина $\Phi_i(S'_t, S)$ называется потенциалом между S'_t и S , и вычисляется следующим образом:

$$\text{а) } \Phi_i(S'_t, S) = \begin{cases} 1, & |\{\alpha_i^j(S) \geq \alpha_i^j(S'_t), j=1,2,\dots,N,\}| / N \geq \delta, \\ 0, & \text{иначе.} \end{cases}$$

$$\text{б) } \Phi_i(S'_t, S) = \{\text{число выполненных неравенств } \alpha_i^j(S) \geq \alpha_i^j(S'_t), j=1,2,\dots,N\}.$$

Назовем потенциал вида а) «монотонным потенциалом», потенциал б) – «слабо-монотонным потенциалом», а параметр $0 < \delta \leq 1$ – мерой монотонности.

Таким образом, этап обучения состоит в обучении N нейросетевых алгоритмов (не совершающих отказов) и последующего вычисления бинарной матрицы $\|\alpha_i^j(S'_t)\|_{l \times N \times q}$. Распознавание нового объекта S осуществляется путем вычисления бинарной матрицы $\|\alpha_i^j(S)\|_{l \times N}$, его оценок за каждый из классов согласно а), или б), и окончательной классификации с помощью решающего правила. Программная реализация данной модели, как уже было указано, дано посредством системы NNLC, квалифицированной как инновационный программный продукт системой грантов организации ИНТАС.

Настоящая работа была выполнена при поддержке ИНТАС 03-56-182 инно, РФФИ (проекты 05-07-90333, 03-01-00580, 05-01-00332), проекта 2.11 Программы Президиума РАН №16 «Математическое моделирование и интеллектуальные системы» и проекта «Мультиалгоритмическое обеспечение задач распознавания, классификации, прогнозирования и принятия решений по прецедентам» Программы Президиума РАН №17 «Параллельные вычисления и многопроцессорные вычислительные системы»

Литература

1. Aslanyan L., Zhuravlev Yu., Logic Separation Principle, Computer Science & Information Technologies Conference // Yerevan, September 17-20, 2001, 151-156.
2. Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики, Наука, Москва, 1978, вып. 33, С. 5-68.
3. Luis Mingo, Levon Aslanyan, Juan Castellanos, Miguel Diaz and Vladimir Riazanov // Fourier Neural Networks: An Approach with Sinusoidal Activation Functions. International Journal Information Theories and Applications. Vol. 11. ISSN: 1310-0513. 2004. Pp. 52-53.
4. Зуев Ю.А. Метод повышения надежности классификации при наличии нескольких классификаторов, основанный на принципе монотонности// ЖВМиМФ. 1981. Т.21. № 1. С.157-167.

О теоретико-информационной эффективности метода блоковых измерений

В.Ф. Бабкин, М.М. Ланге

(Москва)

Измерения детерминированных величин традиционно выполняются по схеме их приближения ближайшими эталонными величинами. При этом погрешность определяется размером делений диапазона измерений, а стоимость измерительного прибора пропорциональна числу делений (эталон). В настоящей работе исследуются схемы измерения независимых стохастических величин, представленных блоками. Рассматриваемая задача сходна задаче классификации [1] и исследуется в терминах соотношения *стоимость-погрешность*. Полученные оценки функции *стоимость-погрешность* базируются на теоретико-информационном подходе, развитом в теории кодирования источников с заданным критерием качества [2].

Формализация задачи

Пусть источник независимых случайных величин задан ансамблем

$$\{X_i, p(x_i), x_i \in X_i, i = \overline{1, n}\}, \quad (1)$$

где X_i и $p(x_i)$ соответственно множество всевозможных значений и плотность распределения значений i -ой величины. Источник (1) порождает блоки $x^n = (x_1, \dots, x_n)$, $x^n \in X^n$, принадлежащие множеству $X^n = \prod_{i=1}^n X_i$. Для измерения блоков x^n используются блоки $y^n = (y_1, \dots, y_n)$, $y_i \in Y_i \subset X_i$, из множества эталонов $Y^n \subset X^n$. При заданных функциях потерь $d(x_i, y_i) \geq 0$ и допустимых значениях $D_i \geq 0$, $i = \overline{1, n}$, средние погрешности измерений отдельных компонентов в блоках x^n должны удовлетворять ограничениям

$$E \left\{ \min_{y_i \in Y_i} d(x_i, y_i) \right\} \leq D_i, \quad i = \overline{1, n}, \quad (2)$$

где матожидания вычисляются по плотностям $p(x_i)$. При распределении $p(y^n)$, $y^n \in Y^n$, на множестве эталонов Y^n (определяется через плотности компонентов $p(x_i)$, $i = \overline{1, n}$) вводится стоимость измерения одного компонента $C_n(y^n) = \left(1/p(y^n)\right)^{\frac{1}{n}} - 1$, которая увеличивается с уменьшением вероятности $p(y^n)$ и равна нулю при $p(y^n) = 1$, так как

при полной определенности y^n необходимость в измерении отпадает. Тогда в терминах соотношения *стоимость-погрешность* оптимизация схемы блоковых измерений состоит в нахождении множества Y^n , на котором при ограничениях (2) достигается

$$C_n(D_1, \dots, D_n) = \min_{Y^n} \max_{y^n \in Y^n} C_n(y^n). \quad (3)$$

Оценивая снизу максимум в формуле (3) матожиданием по распределению $p(y^n)$ и используя неравенство Йенсена [2] $E\{2^{f(y^n)}\} \geq 2^{E\{f(y^n)\}}$ при $f(y^n) = -\frac{1}{n} \log_2 p(y^n)$, получим для стоимости (3) следующую нижнюю границу

$$C_n(D_1, \dots, D_n) \geq (2^{\frac{n \min_{Y^n} H_n(Y^n)}{n}})^{\frac{1}{n}} - 1, \quad (4)$$

где $H_n(Y^n) = -\frac{1}{n} \sum_{y^n \in Y^n} p(y^n) \log_2 p(y^n)$ - энтропия множества Y^n

(в битах на один компонент), а минимум берется по всевозможным Y^n , удовлетворяющим неравенствам (2). Граница (4) выражается через наименьшее число эталонов $2^{\frac{n \min_{Y^n} H_n(Y^n)}{n}}$, которое согласно закону больших чисел [2] при $n \rightarrow \infty$ с вероятностью $\text{Pr} \rightarrow 1$, обеспечивает измерения источника (1) с погрешностями, удовлетворяющими ограничениям (2).

Предлагается следующая схема организации блоковых измерений, обеспечивающая стоимость, близкую к нижней границе (4). На множестве X^n выбирается подмножество $X_c^n \subset X^n$ с параметром c таким, что

$$X_c^n = \{x^n : \text{Pr}(x^n \in X_c^n) \rightarrow 1, n \rightarrow \infty\}. \quad (5)$$

Подмножество (5) покрывается телами-параллелепипедами

$$Q^n(y_k^n) = \{x^n : |x_i - y_{ik}| \leq \frac{1}{2} \Delta_i, i = \overline{1, n}\} \quad (6)$$

с размерами ребер Δ_i и центрами $y_k^n = (y_{1k}, \dots, y_{nk})$, образующими множество эталонов $Y^n = \bigcup_k y_k^n$. Измерения проводятся для блоков $x^n \in X_c^n$ так, что $x^n \rightarrow y_k^n$, если $x^n \in Q^n(y_k^n)$.

В данной работе исследованы две схемы измерений блоков независимых гауссовских величин с различными дисперсиями. Для рассмотренных схем получены верхние границы стоимости измерений в виде функций от допустимых погрешностей.

Основные результаты

Рассмотрен источник вида (1), порождающий независимые случайные величины $x_i \in X_i$ с нормальными плотностями распределения $p(x_i) = N(\mu_i, \sigma_i^2)$, $i = \overline{1, n}$, в которых параметры μ_i и σ_i^2 в общем случае различны. Погрешности покомпонентных измерений определяются квадратичной функцией потерь $d(x_i, y_i) = (x_i - y_i)^2$. Исследованы два способа задания области X_c^n и для них найдены верхние границы стоимости (3). Результаты сформулированы в виде следующих утверждений.

Утверждение 1. При любом $\delta > 0$, $c = 1 + \delta$ и заданных $D_i > 0$, $i = \overline{1, n}$, подмножество $X_c^n = \{x^n : \frac{1}{n} \sum_{i=1}^n \frac{(x_i - \mu_i)^2}{\sigma_i^2} \leq c\}$ и его покрытие телами (6) при $n \rightarrow \infty$ и $\max_{i=1, n} D_i \rightarrow 0$ обеспечивают измерение блоков $x^n \in X_c^n$ со средними относительными погрешностями $\gamma_i \leq \frac{\sqrt{D_i}}{\sigma_i} \leq 1$ компонентов $x_i \in X_i$ и стоимостью

$$C_n(\frac{\sqrt{D_1}}{\sigma_1}, \dots, \frac{\sqrt{D_n}}{\sigma_n}) < (1 + 2\sqrt{3} \max_{i=1, n} \frac{\sqrt{D_i}}{\sigma_i}) \sqrt{(1 + \delta) \frac{\pi e}{6}} 2^{\frac{1}{n} \sum_{i=1}^n \log_2 \frac{\sigma_i}{\sqrt{D_i}}} - 1. \quad (7)$$

Утверждение 2. При любом $\delta > 0$, $c = 1 + \delta$ и заданных $D_i > 0$, $i = \overline{1, n}$, подмножество $X_c^n = \{x^n : |x_i - \mu_i| \leq \sigma_i \sqrt{cn}, i = \overline{1, n}\}$ и его покрытие телами (6) при $n \rightarrow \infty$ и $\max_{i=1, n} D_i \rightarrow 0$ обеспечивают измерение блоков $x^n \in X_c^n$ со средними относительными погрешностями $\gamma_i \leq \frac{\sqrt{D_i}}{\sigma_i} \leq 1$ компонентов $x_i \in X_i$ и стоимостью

$$C_n(\frac{\sqrt{D_1}}{\sigma_1}, \dots, \frac{\sqrt{D_n}}{\sigma_n}) < (1 + 2\sqrt{\frac{3}{n}} \max_{i=1, n} \frac{\sqrt{D_i}}{\sigma_i}) \sqrt{(1 + \delta) \frac{n}{3}} 2^{\frac{1}{n} \sum_{i=1}^n \log_2 \frac{\sigma_i}{\sqrt{D_i}}} - 1. \quad (8)$$

Поскольку в утверждении 1 область измерений задается эллипсоидом, а в утверждении 2 – параллелепипедом, включающим этот эллипсоид, оценка (7) соответствует схеме измерений блоков, а оценка (8) эквивалентна схеме независимых измерений отдельных компонентов. Следует отметить, что стоимость (7) не зависит от длины блока n , а

стоимость (8) растет пропорционально \sqrt{n} . Следовательно, при одновременном измерении большого числа параметров, блоковая схема оказывается эффективнее, чем покомпонентная.

Из теории кодирования источников известно, что для системы нормально распределенных независимых случайных величин и квадратичной меры погрешности, минимум энтропии $H_n(Y^n)$ в границе

(4) равен $\frac{1}{n} \sum_{i=1}^n \log_2 \frac{\sigma_i}{\sqrt{D_i}}$ [2]. Поэтому при высоких точностях, когда $\max_{i=1,n} \frac{\sqrt{D_i}}{\sigma_i} \rightarrow 0$ и $\delta \rightarrow 0$, граница (7) превышает минимально возможную

стоимость лишь в $\sqrt{\pi e/6} \approx 1.193$ раз. Этот результат базируется на асимптотической оптимальности равномерного квантования компонентов источника, которое при квадратичной мере погрешности обеспечивает избыточность энтропии $H_n(Y^n)$ (в битах на компонент), равную $\frac{1}{2} \log_2(\pi e/6) \approx 0.255$ [3].

Аналогичные схемы измерения могут быть построены для источника независимых случайных величин с одномодовыми плотностями распределений более общего типа и степенных мер погрешности. Существенно, что в рассмотренных схемах, погрешности измерений отдельных компонентов могут вычисляться с использованием различных функций потерь.

Работа выполнена при поддержке РФФИ (проект №03-01-00538).

Литература

1. Дуда Р., Харт П. Распознавание образов и анализ сцен. // М.: Мир, 1976.
2. Колесник В.Д., Полтырев Г.Ш. Курс теории информации. // М.: 1982.
3. Кошелев В.Н. Квантование с минимальной энтропией. // Проблемы передачи информации, 1993, вып. 14, с. 151-156.

Интервальное оценивание риска процедуры групповой классификации с использованием несмещенных оценок

Е.В. Бабушкина, В.В. Чичагов

(Пермь)

Важным приложением теории и методов распознавания является групповая классификация n_0 объектов по измерениям их характеристик [1].

Пусть элементы совокупности π_i имеют то же распределение, что и

случайная величина ξ_i , $i = 1, 2$. Плотность распределения классифицируемой выборки $\pi_{00} = \{X_{0,1}, X_{0,2}, \dots, X_{0,n_0}\}$ при условии принадлежности ее к совокупности π_i обозначим $f_{n_0}(x, \theta_i)$. Тогда при известных параметрах θ_i , $i = 1, 2$, оптимальное решающее правило классификации выборки π_{00} имеет вид:

$$\pi_{00} \in \pi_1, \text{ если } q(x) = \ln \frac{\omega_1 f_{n_0}(x, \theta_1)}{\omega_2 f_{n_0}(x, \theta_2)} \geq 0 \quad (1)$$

Неравенство (1) осуществляет разбиение пространства E всевозможных выборок объема n_0 на подпространства E_1, E_2 такие, что

$$E_1 = \{x : q(x) < 0\} \text{ и } E_2 = \{x : q(x) \geq 0\}.$$

Тогда классификация группы π_{00} состоит в проверке принадлежности ее к одному из подпространств E_1 и E_2 , а построение оптимального метода классификации – в построении «наилучшего» разбиения пространства E .

Основной качественной характеристикой правила (1) является байесовский риск

$$R = \sum_{i=1}^2 \omega_i P_{\theta_i}(E_i), \quad P_{\theta_i}(E_i) = \int_{E_i} f_{n_0}(x, \theta_i) dx, \quad (2)$$

где ω_1, ω_2 – некоторые заданные значения.

На практике, в некоторых случаях, пренебрегают возможностью повышения эффективности классификации за счет нахождения точной границы между областями E_1 и E_2 , обеспечивающей минимум (2), и ограничиваются классификацией с фиксированной (заданной) границей [2].

Далее рассматривается задача интервального оценивания риска R , когда параметр θ_i неизвестен и вместо плотности $f_{n_0}(x, \theta_i)$ используется ее несмещенная оценка, вычисляемая по обучающей выборке $\pi_{i0} = \{X_{i,1}, \dots, X_{i,n_i}\}$, $i = 1, 2$.

В настоящей работе предлагается решение этой задачи при следующих предположениях.

(A₁). Распределение с.в. ξ_i принадлежит однопараметрическому экспоненциальному семейству распределения вида

$$f(x, \theta_i) = h(x) \exp\{V_1(\theta_i)T(x) + V_2(\theta_i)\}, \quad x \in G \subset \mathbb{R}, \theta_i \in \Theta.$$

(A₂). Полной достаточной статистикой для параметра θ_i по обучающей

выборке π_{i0} является сумма $S_{i,n_i} = \sum_{j=1}^{n_i} T(X_{i,j})$. Существует такое

$n = N$, при котором с.в. $S_{i,n} / \sqrt{n}$ имеет ограниченную плотность распределения, $i = 1, 2$.

(A₃). $E[T(\xi_i)] = a_i$, $D[T(\xi_i)] = b_i^2$, $E[T(\xi_i) - a_i]^4 < \infty$, $i = 1, 2$.

(A₄). $n_i P_{\theta_i} \left(\left| \sum_{j=1}^{n_0} [T(X_{0,j}) - a_i] \right| \geq n_i^{\gamma_i} \right) \rightarrow 0$ при $n_i \rightarrow \infty$ и

некотором значении $0 < \gamma_i < 0,25$, $i = 1, 2$.

При сделанных предположениях \hat{R} - несмещенная оценка риска R и $\hat{D}[\hat{R}]$ - несмещенная оценка дисперсии $D[\hat{R}]$ во многих случаях могут быть найдены, например, с помощью [3].

Результаты [4] позволяют обосновать утверждение, определяющее асимптотическое поведение этих оценок и позволяющее построить асимптотический доверительный интервал для риска (2).

Теорема. Пусть выполнены предположения (A₁) – (A₄), объемы выборок согласованы таким образом, что

$$\lim_{n_1 \rightarrow \infty} \frac{n_1}{n_2} = k, \quad 0 < k < \infty.$$

Тогда

1) несмещенная оценка $\hat{D}[\hat{R}]$ удовлетворяет при $n_1 \rightarrow \infty$ соотношению

$$n_1 \hat{D}[\hat{R}] \xrightarrow{P} \frac{1}{i(\theta_1)} [P'_{\theta_1}(E_1)]^2 + \frac{k}{i(\theta_2)} [P'_{\theta_2}(E_2)]^2,$$

где $i(\theta)$ - информация Фишера распределения с плотностью $f(x, \theta)$;

2) последовательность $\left\{ \left(\hat{R} - R \right) / \sqrt{\hat{D}[\hat{R}]} \right\}$ нормированных несмещенных оценок риска асимптотически нормальна с параметрами $(0;1)$.

Утверждение теоремы означает асимптотическую эффективность нормированной несмещенной оценки риска $\sqrt{n_1}(\hat{R} - R)$. Вопрос о реальной скорости сходимости последовательности таких оценок и соответственно надежности асимптотических доверительных интервалов при конечных объемах выборок n_1 и n_2 решается с помощью метода статистического моделирования для конкретных семейств распределений.

Сформулированные в работе результаты справедливы и в случае однопараметрического экспоненциального семейства решетчатых распределений с шагом 1.

Исследование выполнено при поддержке гранта РФФИ № 05-01-00229.

Литература

1. Абусев Р.А., Лумельский Я.П. Статистическая групповая классификация // Перм. Ун-т, Пермь, 1987. 92 с.
2. Айвазян С.А., Бухштабер В.М., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: Классификация и снижение размерности // М: Финансы и статистика, 1989. 608 с.
3. Воинов В.Г., Никулин М.С. Несмещенные оценки и их применения. – М.: Наука, 1989. 440 с.
4. Чичагов В.В., Олейник М.А. Интервальное оценивание вероятности $P(X < Y)$ в случае однопараметрических экспоненциальных семейств с использованием несмещенных оценок // Статистические методы оценивания и проверки гипотез. Пермь: Изд-во Перм.ун-та, 2005.С.73-78.

Об одном методе прогнозирования временных рядов с несимметричным функционалом потерь

О.В. Барина

(Москва)

Во многих прикладных задачах прогнозирования и планирования завышение и занижение прогноза влекут за собой потери принципиально разного характера. Например, при планировании объема закупок товара для магазина завышенный прогноз означает замораживание средств, а заниженный прогноз – потерю потенциальной прибыли. Несимметричный кусочно-линейный функционал потерь отражает специфику такого рода

задач более адекватно, чем стандартный квадратичный функционал [2]. Ниже рассматривается обобщение метода экспоненциального скользящего среднего для задач с выраженной сезонностью при несимметричном кусочно-линейном функционале потерь.

Постановка задачи

Пусть известны значения $\{x_t\}_{t=1}^T, x_t \in \mathbf{R}$. Требуется построить прогноз следующего значения ряда x_{T+1} . Обозначим значение прогноза через \tilde{x} . Введем кусочно-линейную функцию потерь:

$$J_0(\tilde{x}, x_{T+1}) = \begin{cases} \lambda_1(\tilde{x} - x_{T+1}) & \text{при } \tilde{x} \geq x_{T+1} \text{ (завышенный прогноз)} \\ \lambda_2(x_{T+1} - \tilde{x}) & \text{при } \tilde{x} < x_{T+1} \text{ (заниженный прогноз)} \end{cases}$$

Предлагается искать \tilde{x} таким образом, чтобы суммарные взвешенные потери на обучении были минимальными:

$$J(x) = \sum_{t=1}^T w_t J_0(x_t, x) \rightarrow \min_{\tilde{x}}. \quad (1)$$

Веса $\{w_t\}_{t=1}^T$ в предлагаемом методе подлежат настройке. Пусть задана весовая функция $\omega(t, \bar{\alpha})$ с вектором параметров $\bar{\alpha}$. При прогнозе $T+1$ -го члена ряда веса $\{w_t\}_{t=1}^T$ вычисляются по формуле $w_t = \omega(T+1-i)$. Параметры весовой функции $\bar{\alpha}$ предлагается настраивать по функционалу скользящего контроля на интервале $[T_0, T]$:

$$V(\bar{\alpha}) = \sum_{t=T_0}^T J_0(\tilde{x}_t, x_t),$$

где \tilde{x}_t – значение прогноза для момента времени t при фиксированных параметрах весовой функции $\bar{\alpha}$. Для выбора параметров весовой функции $\bar{\alpha}$ предлагается решать оптимизационную задачу:

$$V(\bar{\alpha}) \rightarrow \min_{\bar{\alpha}}. \quad (2)$$

При выборе однопараметрической весовой $\omega(t, \gamma) = e^{-\gamma t}$, получим обобщение метода экспоненциального скользящего среднего для задач с несимметричным функционалом потерь J_0 . Для задач с выраженной сезонностью в качестве весовой функции выбираются функции вида $e^{-\gamma t} f(t)$, где $f(t)$ – неотрицательная периодическая функция с заданным

периодом.

Прогнозирование с фиксированными весами

Рассмотрим задачу (1). Поскольку функционал $J(\tilde{x})$ есть кусочно-линейная функция, его минимум достигается в одной из точек излома $\{x_t\}_{t=1}^T$. То есть для нахождения \tilde{x} достаточно вычислить значения функционала $J(\tilde{x})$ в точках $\{x_t\}_{t=1}^T$. Процедуру минимизации $J(\tilde{x})$ можно упростить, воспользовавшись следующими соображениями.

Пусть для определенности $\lambda_2 > \lambda_1$. Введем функцию

$$F(x) = \sum_{k: x_k \leq x} w_t \Big/ \sum_{t=1}^T w_t.$$

Упорядочим значения ряда по возрастанию: $x_{k_1} \leq x_{k_2} \leq \dots \leq x_{k_l}$.

Функционал $J(\tilde{x})$ имеет единственный минимум, причем для его точки минимума x_{k_j} выполняется следующее условие:

$$x_{k_j} : \begin{cases} F(x_{k_{j-1}}) < \frac{\lambda_2}{\lambda_1 + \lambda_2} \\ F(x_{k_j}) \geq \frac{\lambda_2}{\lambda_1 + \lambda_2} \end{cases}.$$

Таким образом, для поиска \tilde{x} не требуется вычислять значение функционала $J(\tilde{x})$ в каждой из точек $\{x_t\}_{t=1}^T$. Процедура вычисления значения прогноза при фиксированных весах состоит в поиске прецедента, удовлетворяющего указанным выше условиям.

Настройка весов

Из условия минимума $J(\tilde{x})$ следует, что прогноз \tilde{x} равен одному из прецедентов $\{x_t\}_{t=1}^T$, то есть может принимать лишь конечное число значений. Значит, функционал качества алгоритма на скользящем контроле $V(\bar{\alpha})$ также может принимать лишь конечное число значений. Значение функционала $V(\bar{\alpha})$ меняется скачками, то есть функционал качества алгоритма на скользящем контроле не дифференцируем по параметрам весовой функции $\bar{\alpha}$. Таким образом, для минимизации $V(\bar{\alpha})$ нельзя применить градиентные методы оптимизации.

Из приведенного выше условия минимума функционала $J(\tilde{x})$ следует, что если значение функции F в некоторой точке x близко к величине $\frac{\lambda_2}{\lambda_1 + \lambda_2}$, то значение прогноза \tilde{x} , полученное описанным методом, близко к x . Выполняется следующее приближенное равенство:

$$F(\tilde{x}) \approx \frac{\lambda_2}{\lambda_1 + \lambda_2}$$

Этот факт можно использовать для настройки параметров весовой функции. Рассмотрим еще один функционал качества алгоритма на скользящем контроле:

$$W(\bar{\alpha}) = \sum_{t=T_0}^T J_0 \left(\frac{\lambda_2}{\lambda_1 + \lambda_2}, F^{(t)}(x_t) \right),$$

где $F^{(t)}(x_t)$ – значение функции F , построенной при прогнозе t -го значения ряда, в точке x_t . По аналогии с (2), для выбора вектора параметров весовой функции $\bar{\alpha}$ предлагается решать оптимизационную задачу

$$W(\bar{\alpha}) \rightarrow \min. \quad (3)$$

Поскольку функция потерь является кусочно-линейной функцией x , функция F есть линейная комбинация весов $\{w_t\}_{t=1}^T$, которые вычисляются как значения весовой функции $\omega(t)$ в различных точках t , функционал $W(\bar{\alpha})$ представляет собой линейную комбинацию значений весовой функции в различных точках. Таким образом, если весовая функция $\omega(t)$ дифференцируема по параметрам $\bar{\alpha}$, то и функционал $W(\bar{\alpha})$ дифференцируем по $\bar{\alpha}$, значит, для его минимизации можно использовать градиентные методы.

Заметим, что последний метод настройки параметров весовой функции не требует вычисления значений прогнозов на интервале $[T_0, T]$. Достаточно получить производную функционала $W(\bar{\alpha})$, которая является линейной комбинацией значений производных весовой функции $\omega(t)$ по параметрам $\bar{\alpha}$ в различных точках t .

Литература

1. Arminger G., Schneider C. Frequent problems of model specification and forecasting of time series in goods management systems: Tech. Rep. 21/1999, SFB 475: University of Dortmund, 1999.
2. Arminger G., Schneider C. Asymmetric loss functions for evaluating the

- quality of forecasts in time series for goods management systems: Tech. Rep. 22/1999, SFB 475: University of Dortmund, 1999.
- Schneider C., Klapper M., Wenzel T. An evaluation of forecasting methods and forecast combination methods in goods management systems: Tech. Rep. 31/1999, SFB 475: University of Dortmund, 1999.
 - Crone S. F. Training artificial neural networks for time series prediction using asymmetric cost functions // Computational Intelligence for the E-Age. - 2002. - Pp. 2374-2380.

О прогнозирующей способности методов распознавания

В.Б. Бериков, Г.С. Лбов

(Новосибирск)

В задачах распознавания требуется находить решающую функцию при ограниченном объеме обучающей выборки. Существуют различные методы построения решающих функций по выборкам (методы обучения). Одним из наиболее важных свойств метода обучения, определяющим его качество, является способность находить решающие функции, обладающие достаточно низким риском неправильного распознавания объектов, не входящих в обучающую выборку (прогнозирующая способность метода).

Вообще говоря, все методы явно или неявно используют либо ограничения на предполагаемое семейство распределений, либо ограничения на класс решающих функций. Под устойчивостью метода понимается сохранение его прогнозирующей способности при нарушении указанных ограничений и изменении объема выборки. При исследовании устойчивости того или иного метода необходимо установить взаимосвязь между сложностью семейства распределений, сложностью класса решающих функций, объемом обучающей выборки.

Возникают следующие теоретические вопросы:

Как вводить ограничения на сложность семейства распределений? Например, в работе [1] предложен один из способов введения такой сложности.

Как вводить ограничения на сложность класса решающих функций? Для этого может быть использовано понятие емкостной характеристики (VC-размерности) [2].

Как оценивать прогнозирующую способность метода по ограниченной выборке, и каким должен быть объем обучающей выборки, чтобы обеспечить приемлемое качество решений в зависимости от указанных ограничений?

Следующий вопрос связан с формулировкой принципов, которыми следует руководствоваться при выборе решающей функции: требуется определить, какова должна быть оптимальная сложность класса

решающих функций или семейства распределений при заданном объеме выборки.

В настоящее время существуют классические подходы к анализу прогнозирующей способности методов распознавания: подход, использующий принципы многомерного статистического анализа (см. обзоры в работах [3,4]), подход В.Н.Вапника и А.Я.Червоненкиса (статистическая теория обучения) [2,5], байесовский подход (называемый также теорией байесовского обучения), представленный, например, в работах [6–10].

Кроме того, в последнее время появился и ряд других направлений: алгоритмический подход [11], в котором учитывается также трудоемкость метода построения решающих функций (в рамках этого направления существуют работы, использующие как статистическую теорию обучения, так и байесовский подход); экспериментальный подход [12], основанный на использовании процедуры скользящего контроля и ее модификаций; подход, использующий свойство равномерной сходимости применительно к дискретной задаче распознавания [13].

В многомерном статистическом анализе в основном используется предположение о нормальном законе распределения. Статистическая теория обучения применяется для произвольных классов решающих функций и распределений, однако этот подход ориентирован на получение оценок для наилучшего случая распределения. Поэтому полученные оценки прогнозирующей способности являются сильно заниженными. В байесовском подходе получаются оценки в среднем, которые являются более соответствующими практическим задачам.

В работе [7] прогнозирующая способность методов изучалась при произвольных распределениях в рамках байесовского подхода для конечного числа событий. Под задачей распознавания образов по конечному множеству событий понимается задача распознавания, возникающая при разбиении пространства переменных на некоторое конечное число подобластей (под событием понимается принятие вектором переменных значения из некоторой подобласти). Если ввести новую переменную, значениям которой соответствуют данные подобласти, получим задачу распознавания по значениям одной дискретной неупорядоченной переменной.

К задаче распознавания по конечному множеству событий может быть сведена любая задача распознавания, при решении которой используется произвольный класс решающих функций и метод обучения. Для того чтобы провести такое сведение, можно использовать следующую методику. По некоторой случайно отобранной части обучающей выборки нужно найти решающую функцию; затем по этой функции образовать разбиение пространства переменных (способы образования разбиения

могут различаться для разных классов решающих функций). Оставшаяся часть выборки (которая не зависит от структуры разбиения) используется далее как обучающая выборка при решении задачи распознавания по конечному множеству событий.

В работах [10,14-15] анализ прогнозирующей способности методов изучается также для конечного числа событий. В отличие от [7], получены интервальные оценки качества для произвольных методов обучения. Наиболее детально исследовался метод минимизации эмпирической ошибки. Кроме того, полученные теоретические результаты распространены на методы распознавания в классе логических решающих функций (деревьев решений). Разработан ряд новых методов построения деревьев решений [16]. Исследование этих методов на тестовых и прикладных задачах анализа данных в области медицины, биоинформатики и др. показало их достаточно высокую эффективность по сравнению с существующими методами.

Работа выполнена при поддержке РФФИ (грант 04-01-00858а).

Литература

1. Лбов Г.С., Старцева Н.Г. Сложность распределений в задачах классификации // Докл. РАН. 1994. Т.~338, № 5. С. 592--594.
2. Вапник В.Н., Червоненкис А.Я. Теория распознавания образов. М.: Наука, 1979. 415 с.
3. Раудис Ш. Влияние объема выборки на качество классификации (обзор) // Статистические проблемы управления. Вильнюс, 1984, Вып.66. С.9-42.
4. Шурыгин А.М. Прикладная стохастика: робастность, оценивание, прогноз. – М.: Финансы и статистика, 2000. – 224 с.
5. Vapnik V.N. An Overview of Statistical Learning Theory. // IEEE Transactions on Neural Networks. 1999. V. 10, N 5. P. 988-999.
6. Hughes G.F. On the mean accuracy of statistical pattern recognizers // IEEE Trans. Inform. Theory. 1968. V. IT-14, N 1. P. 55-63.
7. Лбов Г. С., Старцева Н.Г. Логические решающие функции и вопросы статистической устойчивости решений. Изд-во Института математики СО РАН, Новосибирск, 1999.
8. Гуров С.И. Оценка надежности классифицирующих алгоритмов. Учебное пособие. М.:Изд-во МГУ, 2002.
9. D.Haussler, M.Kearns, and R.Schapire. Bounds on sample complexity of Bayesian learning using information theory and the VC dimension // Machine Learning, N 14, 1994. pp. 84-114.
10. В.Б.Бериков, Г.С.Лбов. Байесовские оценки качества распознавания по конечному множеству событий // Доклады Академии Наук. Т. 402, № 1. 2005. С. 1 - 4.
11. Valiant L.G. A Theory of the Learnable, CACM, 17(11):1134-1142, 1984.

12. Воронцов, К. В. Комбинаторные оценки качества обучения по прецедентам // Доклады РАН, Т.394, N 2. 2004.
13. V.M. Nedel'ko, On the accuracy of Vapnik-Chervonenkis Risk Estimations in discrete case// PRIP'2003, Minsk, Proc. of the Seventh International Conference, Vol 2, pp.75-79.
14. Berikov, V.B., Litvinenko A.G. The influence of prior knowledge on the expected performance of a classifier // Pattern Recognition Letters, Vol. 24, N 15, 2003, pp. 2537-2548.
15. Бериков В.Б. Априорные оценки качества распознавания при ограниченном объеме обучающей выборки. // Журнал вычислительной математики и математической физики 2003, том 43, №9, с.1448 -1456.
16. <http://www.math.nsc.ru/AP/datamine /decisiontree.htm>

**Кодирование цифровых изображений с помощью
дискретных ортогональных преобразований с
«хаотическими» базисными функциями**

О.В. Бесполитов

(Самара)

Одним из важных свойств «классических» дискретных ортогональных преобразований, определяющим их эффективность в задачах кодирования цифровой видеоинформации, является концентрация энергии спектра в относительно небольшом числе спектральных компонент. В задачах компрессии изображений это свойство определяет эффективность конкретных алгоритмов компрессии. С другой стороны, при передаче кодированной видеоинформации по реальному каналу возникают помехи, зависящие от физической природы канала. Если специфика канала такова, что часть передаваемой информации *случайным образом* утрачивается («канал с пропусками»), то при утрате «энергетически значимых» компонент спектра на изображение накладываются «структурированные помехи», к которым чувствительна зрительная система человека. Поэтому целесообразно рассматривать преобразования, которые не обладают свойством «концентрации» энергии в нескольких спектральных компонентах. Так, чтобы в процессе кодирования/декодирования видеоинформации влияние канальных ошибок было бы менее заметно и имело вид точечного шума, в отличие от случая применения классических дискретных ортогональных преобразований Фурье, Уолша, Хартли и др., для которых искажения имеют структурированный вид. Такие преобразования (M -преобразования) базисные функции которых принимают два значения с равными частотами, введены и исследованы в [1], [2].

Основой для построения базисных функций преобразований

$$\hat{x}(m) = \sum_{n=0}^{N-1} x(n)h_m(n), \langle h_u, h_v \rangle = \sum_{n=0}^{N-1} h_u(n)h_v(n) = \delta_{uv} \cdot N \quad (1)$$

являлись рекуррентные последовательности

$$y(n) = a_1 y(n-1) + \dots + a_r y(n-r); a_j \in \mathbf{F}_2, a_r \neq 0$$

элементов поля \mathbf{F}_2 с периодом $N = 2^r - 1$ (m -последовательности). В процессе построения базисных функций члены последовательности $y(n)$ заменялись числами $h_m(n)$ таким образом, чтобы для функции $h_m(n)$ были ортогональными.

В настоящей работе обобщаются результаты работ [1], [2], а именно, синтезируются M -преобразования, значения базисные функций распределены по полиномиальному закону.

Основным результатом, гарантирующим построение ортогональных базисов $h_m(n)$, является следующее утверждение.

Теорема. Пусть p – простое число, $N = p^r - 1$, числа A_0, \dots, A_{p-1} удовлетворяют соотношению

$$A_k = k \frac{A_{p-1} - A_0}{p-1} + A_0, (k = 0, \dots, p-1).$$

Пусть функции $h_m(n)$ определены соотношениями

$$\begin{cases} h_0(n) = A_k, \text{ если } y(n) = k; \\ h_m(n) = h_0(m+n). \end{cases}$$

Тогда существуют эффективно вычисляемые константы A_0 и A_k , такие что семейство функций $\{h_m(n); m, n = 0, 1, \dots, N-1\}$ образует ортонормированный базис, причем константы $A = A_0$ и $C = A_{p-1}$ являются решением системы уравнений

$$\begin{cases} N = A^2(p^r - 1) + ACp^r(p-1) + C^2p^r(p-1)\frac{2p-1}{6} \\ 0 = \sum_{i=0}^{p-1} \sum_{j=0}^{p-1} (A + Ci)(A + Cj)S_{ij}(\tau) \end{cases},$$

где

$$S_{ij}(\tau) = \begin{cases} p^{-2}N + p^{-2} - 1, & \text{если } i = j = 0; \\ p^{-2}N + p^{-1}, & \text{если } i = 0, j \neq 0 \text{ или } i \neq 0, j = 0; \\ p^{-2}N + p^{-2}, & \text{если } i \neq 0, j \neq 0. \end{cases}$$

В докладе приводятся также результаты численных экспериментов по применению предложенного метода кодирования при различных развертках двумерного изображения в одномерный массив, обеспечивающих применение преобразования (1).

Литература

1. Grallert H.-J. Application of orthonormalized m-sequences for data reduced and error protected transmission of pictures // Proc. IEEE Int. Symp. on Electromagnetic Compability. – Baltimore, MD, 1980. – pp. 282-287.
2. Musmann H.G., Pirsch P., Grallert H.-J. Advances in picture coding // IEEE Proc. – 1985. – v. 73, № 4. – pp. 523-548.

О построении коллективных решений при решении задач кластерного анализа

А.С. Бирюков, В.В. Рязанов
(Москва)

Рассматривается задача кластеризации числовой прецедентной информации, заданной в виде таблицы признаков описаний объектов, ситуаций или явлений при известном числе кластеров.

К настоящему времени известно большое число разнообразных алгоритмов кластеризации, основанных на различных принципах и идеях. Методы, основанные на минимизации некоторого критерия качества разбиения, предусматривают экономный перебор (обычно локальный) различных разбиений заданной выборки и выбора разбиения с минимальным значением заданного критерия качества. В агломеративных процедурах иерархической группировки происходит последовательное объединение ближайших группировок объектов до достижения требуемого их числа [2]. Алгоритм Форель основан на «движении»

гиперсфер фиксированного радиуса до достижения ими таких расположений, когда центры гиперсфер совпадают с выборочным средним всех принадлежащих им объектов [5]. При использовании статистической модели происхождения кластеров, задача их поиска сводится к восстановлению плотностей компонент по плотности смеси используя выборку, полученную согласно плотности смеси. Одним из наиболее простых и надежных является метод k -средних [2]. Известны также и многие другие модели кластеризации (основанные на теории графов, нечетких множествах, эвристические и др. [1, 2]).

Основными проблемами их практического применения являются стандартные оптимизационные сложности дискретного перебора, большое число локальных экстремумов, вычисление вырожденных решений, наличие кластеров различной конфигурации и размера.

В работе [6] был предложен подход для построения решений задач кластеризации множествами алгоритмов. На первом этапе находится набор «базисных» кластеризаций, полученных независимо различными алгоритмами. Решение задачи кластеризации определяется как вычисление некоторого класса эквивалентных информационных матриц. На втором этапе по имеющемуся набору кластеризаций вычисляется окончательное решение задачи кластерного анализа, оптимальное в определенном смысле. В рамках комитетного синтеза коллективных решений находятся кластеры, объекты которых принадлежат «значительному числу» одних и тех же базисных кластеризаций.

В настоящей работе рассматриваются вопросы обобщения комитетного склеивания, альтернативные пути синтеза коллективных решений, задача выбора и построения коллектива исходных базисных решений.

Многие алгоритмы кластеризации позволяют ввести числовые оценки степени близости объектов к каждому из кластеров. Тогда можно считать, что данные (взятые в качестве базисных) алгоритмы кластеризации вычисляют дополнительно числовые матрицы оценок (степени близости объектов к каждому из кластеров), элементы которых принадлежат интервалу $[0, 1]$. По аналогии с задачей распознавания, алгоритм кластеризации представляется как последовательное вычисление матрицы оценок и информационных матриц [3]. Для данного случая получен аналог алгоритма комитетного синтеза [6]. Предложены эвристические методы построения коллективных решений по множествам матриц оценок или информационным матрицам.

Предложены два подхода для построения базисных кластеризаций при числовых признаках.

Первый подход основан на анализе выборки независимо по каждому из признаков и вычислении кластеризаций (и матриц оценок) по каждому из признаков. В его основе лежит гипотеза, что кластеры являются сгустками

объектов, имеющих форму эллипсоидов или параллелипипедов, оси которых параллельны координатным осям. По исходной выборке строятся эмпирические функции плотности для каждого из признаков. Здесь удобно использовать статистическую модель кластеризации, когда решаются задачи восстановления плотностей компонент по плотности смеси на основе заданной выборки при статистически независимых признаках. Предполагается, что функциональный вид плотностей известен (неизвестны числовые параметры плотностей). Задача восстановления l одномерных плотностей кластеров формулируется как задача поиска наилучшей аппроксимации плотности смеси в виде линейной комбинации l функций на заданной сетке функций. Для ее решения разработан специализированный генетический алгоритм. Для случая равномерных распределений предложен алгоритм, основанный на поиске в двудольном графе паросочетания максимального веса.

Другим перспективным подходом для построения множества базовых кластеризаций представляется генерация множеств локально оптимальных кластеризаций в рамках некоторого общего алгоритма. С данной целью предложен алгоритм кластеризации многомерных данных, основанный на решении задачи поиска покрытий выборки объектов набором из l гипершаров, имеющих минимальное пересечение по объектам выборки. Гипершары выбираются из l конечных множеств вложенных гипершаров с единым центрами. Таким образом, для нахождения некоторой оптимальной кластеризации требуется задание l точек в R^n , в качестве которых естественно использовать средние из метода k -средних или центры гипершаров алгоритма Форель.

Многочисленные сравнительные численные эксперименты были проведены на модельных задачах - смесях выборок с нормальными плотностями при независимых признаках. Параметры распределений выбирались таким образом, чтобы точность байесовского классификатора на данной выборке была близкой к 100% точных ответов. Для задач данного типа весьма эффективным является восстановление компонент смеси по методу максимального правдоподобия. Причем данные задачи решались успешно при существенно различных комбинациях значениях дисперсий и математических ожиданий, а полученные результаты превосходили полученные как другими известными подходами (для сравнения использовались методы системы РАСПОЗНАВАНИЕ [4]), так и коллективные решения. Тем не менее, с ростом числа кластеров (и соответственно сложности соответствующей оптимизационной задачи) ситуация становится обратной: при $l > 15$ точность статистического алгоритма снижается до 90%, а точность алгоритма синтеза коллективных кластеризаций становится близкой к 100%.

Настоящая работа была выполнена при поддержке ИНТАС 04-77-7036,

РФФИ (проекты 05-07-90333, 03-01-00580, 05-01-00332), Целевой программы отделения Математических наук РАН №2, и проекта «Мультиалгоритмическое обеспечение задач распознавания, классификации, прогнозирования и принятия решений по прецедентам» Программы Президиума РАН №17 «Параллельные вычисления и многопроцессорные вычислительные системы»

Литература

1. Айвазян С.А. и др. ПРИКЛАДНАЯ СТАТИСТИКА: Классификация и снижение размерности // М. Финансы и статистика, 1989, 607 с.
2. Дуда Р., Харт П., Распознавание образов и анализ сцен // Издательство «Мир», Москва, 1976, 511 с.
3. Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики, Наука, Москва, 1978, вып. 33, С. 5-68.
4. Журавлев Ю.И., Рязанов В.В., Сенько О.В., Бирюков А.С., Ветров Д.П., Докукин А.А., Катериночкина Н.Н., Кропотов Д.А., Обухов А.С. Романов М.Ю., Рязанов И.В., Челноков Ф.Б. Разработка универсальной программной системы интеллектуального анализа данных, распознавания и прогноза // Доклады 11-й Всероссийской конференции «Математические методы распознавания образов, 2003, С. 311-314.
5. Загоруйко Н.Г. Методы распознавания и их применение // М. : Сов.радио, 1972. -206 с.
6. Рязанов В.В. О синтезе классифицирующих алгоритмов на конечных множествах алгоритмов классификации (таксономии) // ЖВМ и МФ, 1982. Том 22, №2. С.429-440.

Формирование тестов с минимальными затратами ресурсов и времени на частотных таблицах

Ю.А. Бродская

(Саратов)

Доклад посвящен задаче формирования тестов с минимальными затратами ресурсов (T_{π}) или времени (T_{ξ}) при измерении значений признаков распознаваемых объектов – на частотной таблице (ЧТ) как виде представления обучающей выборки (ОВ). Доклад является продолжением работ [1-4].

ЧТ – таблица, в строках которой заданы распределения объектов из классов разбиения ОВ по значениям признаков $x_i \in X$ априорного словаря признаков X ; $i=1, \dots, n$. Необходимость рассмотрения предполагаемой задачи вызвана тем, что:

- а) использование ЧТ позволяет существенно уменьшить затраты на

хранение ОБ и выполнение задач обучения [5];

б) в ряде наук (биологии, медицине, химии, социологии, психологии и др.) созданы и поддерживаются представительные выборки эталонных объектов в виде ЧТ, например, в [5,6].

ЧТ составляются (могут составляться) на основе стандартных описаний ОБ. Однако соответствие между стандартным описанием ОБ и ЧТ не является взаимно однозначным. В связи с этим возникают проблемы при формировании T_π и T_ξ на ЧТ. Некоторые из них рассмотрены в [2].

ЧТ содержит l строк, соответствующих классам K_j в ОБ; $j=1, \dots, l$, и Θ столбцов, соответствующих всем или некоторым (учтенным в ЧТ)

значениям признаков x_i : $\Theta = \sum_{i=1}^n k_i - q_i$, где $k_i(q_i)$ – общее количество

(количество неучтенных в ЧТ) значений признака x_i . На пересечении j -ой строки и h -го столбца ЧТ; $h=1, \dots, \Theta$: или количество объектов, или доля количества объектов от их общего количества, или доля, выраженная в %, взятых из класса K_j ОБ, имеющих значение q_i признака x_i ; $q_i=1, \dots, k_i$.

Очевидно, что все три вида представления строк ЧТ связаны между собой взаимно однозначным соответствием. Здесь рассматривается 1-ый вид представления ЧТ. Элементами конечных множеств значений признаков M_i ($|M_i| \geq 2$) могут быть: а) целые неотрицательные числа; б) номера интервалов целых неотрицательных или вещественных чисел; в) символьные строки.

Неопределенные значения признаков являются запрещенными для эталонных объектов. Метрика d_i на множестве M_i имеет вид:

$$d_i(a_i^1, a_i^2) = \begin{cases} 1, & \text{если } a_i^1 \neq a_i^2 \\ 0, & \text{если } a_i^1 = a_i^2 \end{cases}$$

Тесты T_π и T_ξ формируются как кратчайшие столбцовые покрытия строк частотной матрицы различий (ЧМР), создаваемой на основе ЧТ, при условии, что строкам ЧМР, покрываемым столбцом-признаком x_j ;

$i=1, \dots, t$, присваиваются веса $V_{\pi i} = \frac{1}{z_i}$ или $V_{\xi i} = \frac{1}{\xi_i}$. Здесь: $z_i(\xi_i)$ -

затраты ресурсов (времени) при измерении значений признака x_j . Затраты

времени ξ_i определяются по сетевой модели комплекса работ по измерению значений признаков [1,4], $t = |T_\pi|$ или $t = |T_\xi|$.

Столбцовые покрытия строк ЧМР при различных значениях $z_i(\xi_i)$ для разных признаков x_i являются неприводимыми; при $z_1 = z_2 = \dots = z_n$ - кратчайшими.

ЧМР содержит $l(l-1)/2$ строк и n столбцов. Элемент ЧМР определяется так:

$$c_{pi} = \left(\sum_{q_i=1}^{k_i-q_i} m_{j_1}^{q_i} (m_{j_2} - m_{j_2}^{q_i}) \right) + \left(m_{j_1} - \sum_{q_i=1}^{k_i-q_i} m_{j_1}^{q_i} \right) \times \sum_{q_i=1}^{k_i-q_i} m_{j_2}^{q_i};$$

где: $m_j^{i(q)}$ - количество объектов подмножества $M_j \subset M$, p - номер строки ЧМР; $p = 1, \dots, l(l-1)/2$; $p(j_1, j_2) = (j_1 - 1) \cdot l - j_1(j_1 + 1)/2 + j_2$; $j_1 = 1, \dots, l-1$; $j_2 = 2, \dots, l$; $j_1 < j_2$; j_1, j_2 - строки ЧТ. c_{pi} - это количество пар объектов из классов K_{j_1} и K_{j_2} со значениями признаков $a_i^{j_1}$ и $a_i^{j_2}$, для которых метрика $d_i(a_i^{j_1}, a_i^{j_2}) = 1$. Очевидно, общее количество пар объектов, взятых из классов K_{j_1} и K_{j_2} ОВ, соответствующих строке $p(j_1, j_2)$, равно $m_{j_1} \times m_{j_2}$.

Методы формирования T_π и T_ξ опираются на два метода из [2] с учетом отличий задач в докладе от задач в [2]. 1-ый метод в [2] опирается на гипотезу о равномерном распределении значений признаков на координатных осях признакового пространства. 2-ой метод опирается на гипотезу о распределении, близком к нормальному.

Предварительные испытания методов формирования T_π и T_ξ показали приемлемость принятых подходов. Однако для реализации методов требуются большие затраты вычислительных ресурсов. Эти затраты могут быть значительно уменьшены, если в ЧТ (на основе которой создана ЧМР) существуют пары строк (j_1, j_2) такие, что на пересечении их с некоторым столбцом h имеются числа: $c_{j_1 h} \geq m_{j_1} (100\% - \eta\%) / 100\%$ и $c_{j_2 h} \leq m_{j_2} \cdot \eta\% / 100\%$ ($\eta\%$ - допустимое максимальное отклонение в конкретном приложении),

которые заменяются на числа: $c_{j_1 h} = m_{j_1}$ и $c_{j_2 h} = 0$, соответственно. Данное утверждение следует из анализа формулы для c_{pi} (см. выше) и выводов в [2].

Литература

1. Бродская Ю.А. Распознавание образов при заданных ограничениях // Доклады 11-ой Всероссийской конф. «Математические методы распознавания образов». – М.: ВЦ РАН, 2003. – С.30-33.
2. Бродская Ю.А. О методах формирования кратчайших покрытий небулевых матриц // Автоматизация проектирования дискретных систем: Мат. Пятой междунар. Конф. – Т.1. – Мн: ОИПИ НАН Беларуси, 2004. – С.- 162-169.
3. Бродская Ю.А. Методы формирования кратчайших покрытий булевой матрицы с минимальными затратами в задачах распознавания образов // Искусственный интеллект. – 2004. - №2. - С.- 22-27.
4. Бродская Ю.А. Распознавание объектов при ограничениях во времени // Проблемы точной механики и управления: Сб. научн. тр. ИПТМУ РАН. – Саратов, 2004. – С.166-170.
5. Штейн Л.Б. Опыт прогнозирования в медицине с помощью ЭВМ – Л.: Изд-во Ленингр. ун-та, 1987. – 146 с.
6. Бациллы. Генетика и биотехнология: Пер. с англ. – М.: Мир, 1992. – 531с.

Троичная компьютеризация логики

Н.П. Брусенцов, Ю.С. Владимирова

(Москва)

Конструктивная компьютеризация булевой алгебры [1, 2] путем представления n -арных СДНФ и СКНФ выражений совокупностями n -битных векторов (двоичными ДК- и КД-цепями), а также 2^n -битными векторами (двоичными ДК- и КД-шкалами) позволила перепоручить компьютеру выполнение алгебраических операций над n -арными булевыми функциями, включая решение логических уравнений. При использовании совокупностей n -тритных векторов (троичных ДК- и КД-цепей) для представления n -арных ДНФ и КНФ выражений компьютеру перепоручена минимизация этих выражений в рамках современной булевой алгебры четких классов [3]. Однако несравнимо большие возможности совершенствования и развития логики открывает применение упомянутых в [1] троичных ДК- и КД-шкал, обобщающее булеву алгебру в алгебру нечетких классов [4].

Так же как в двоичных ДК- и КД-шкалах, компоненты 2^n -тритного вектора троичных шкал сопоставлены индивидуальным конъюнкциям

(предполным дизъюнкциям) СДНФ (СКНФ) выражения, но значений, принимаемых компонентами троичных шкал, не два, а три: включено (+), исключено (-), приводяще (0) – не включено и не исключено. Шкалы, не содержащие приводящих компонент, обозначают четкие классы, выразимые в обычной, необобщенной булевой алгебре, а при наличии хотя бы одной приводящей компоненты класс оказывается нечетким, характеристическая функция его трехзначна. Логика троичных ДК- и КД-шкал отличается от изобретенных Яном Лукасевичем, фон Вригтом и другими «трехзначниками» тем, что первичные (несоставные) термины в ней четкие, двухзначные, как то принято Аристотелем в «началах доказательства» [«Метафизика», 946в27], а третье-приводящее возникает лишь на уровне суждений, выражающих отношения, охарактеризованные функциями терминов. Короче, троичными шкалами представлены трехзначные функции двухзначных терминов-переменных.

Простой и принципиально значимый пример суждения, не отображимого в алгебре четких классов, – общеутвердительная силлогистическая посылка «Все x суть y ». Именно отсутствием в двухзначной логике третьего-приводящего обусловлена неадекватность истолкования этой посылки в смысле парадоксальной материальной импликации и нелепость неподчиненности частного общему. У Аристотеля ничего подобного нет.

Соотнеся тригты ДК-шкалы индивидуальным конъюнкциям при $n=2$ в последовательности $xy, xy', x'y, x'y'$, аристотелево здоровое истолкование посылки «Все x суть y » получим в виде: $+0+$, тогда как материальная импликация соответствует четкому классу: $+--+$. Частноутвердительная посылка «Некоторые x суть y », необходимо подчиненная общеутвердительной, кодируется шкалой $+00+$. Общеотрицательная и частноотрицательная посылки представлены соответственно шкалами $-++0$ и $0++0$.

Доказательство правильных модусов силлогизма, в том числе «сомнительных» с точки зрения современной математической логики, а также упущенных самим Аристотелем, выполняется компьютером в форме стандартной процедуры манипулирования шкалами, кодирующими посылки [5].

Например, доказательство «сомнительного» модуса третьей фигуры *felapton* осуществляется так:

$$\begin{aligned} EyzAx &\equiv (-++0)_{yz} \cap (+0-)_{xy} \equiv (-++0 \text{ } -++0)_{xyz} \cap (+00 \text{ } --++)_{xyz} \equiv \\ &\equiv (-+00 \text{ } --+0)_{xyz} \Rightarrow (0++0)_{xz} \Rightarrow Oxz. \end{aligned}$$

Исчерпывающей компьютеризацией силлогистики при помощи троичных ДК-шкал устранены многочисленные пробелы и извращения этой фундаментальной системы умозаключения, выявлен ее подлинно

диалектический характер, безупречная адекватность действительности [6].

Литература

1. Конструктивная компьютеризация булевой алгебры. // Доклады 11-й Всероссийской конференции «Математические методы распознавания образов». – М.: ВЦ РАН, 2003. С. 33-34.
2. Компьютеризация булевой алгебры. // Доклады Академии Наук, 2004, Том 395, № 1. С. 7-10.
3. Троичный минимизатор булевых выражений. // Программные системы и инструменты. № 2. – М.: Издательский отдел факультета ВМиК МГУ, 2001. С. 205-208.
4. Обобщение булевой алгебры. // Программные системы и инструменты. № 5. – М.: Издательский отдел факультета ВМиК МГУ, 2005. С. 6-9.
5. Булевы уравнения и логический вывод. // Программные системы и инструменты № 5. – М.: Издательский отдел факультета ВМиК МГУ, 2005. С. 10-12.
6. Реанимация аристотелевой силлогистики // Реставрация логики. – М.: Фонд «Новое тысячелетие», 2005. С. 140-145.

Архитектура и функции модели организации поведения

М.Н. Вайнцвайг, М.П. Полякова

(Москва)

В последнее время становится все более очевидным, что основные проблемы построения моделей организации поведения связаны со спецификой обработки сенсорной информации, отражающей пространственно-временные характеристики внешнего мира. Поэтому, в отличие от большинства работ по нейронным сетям, практически не касающихся специфики предметных областей, наш подход [1-6] базируется на конкретных свойствах внешнего мира, в частности, на его представлении в виде движения и взаимодействия разного рода предметов. Поскольку главную роль в формировании представлений о предметах и их динамики играет зрение, то в предлагаемой модели основное внимание уделяется рассмотрению процессов обработки зрительной информации.

В основе модели лежит взаимодействие двух блоков: *входного анализатора* и *ассоциативной памяти*, связанных между собой *полем внимания*.

Входной анализатор выполняет предварительную обработку картин возбуждения рецептивных полей, преобразуя их в *объекты памяти*, т.е. элементы структурно-языковых выражений. Представляя собой систему полей-преобразователей, управляемых внутренними критериями и полем внимания, он (решая, в частности, задачи стереопсиса) строит пирамиду сенсорных картин различных уровней разрешения и на каждом из уровней производит:

- вычисление пространственно-временных производных и градиентов;
- разбиение картины на области однородности (по цвету, текстурам, скоростям и пр.);
- выделение объектов O_i (особенностей границ и траекторий движения, элементов текстур, предметов и пр.) и связывающих их соотношений v_{ij} (равенств, отношений объект-подобъект, относительных координат, характеристик динамики и пр.),
- вычисление важности объектов O_i (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_j .

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 местом хранения структурной информации и распределенным устройством, осуществляющим ее параллельную (ассоциативную) обработку, результатами которой являются:

- обучение, т.е. основанное на обобщении формирование понятий, законов и правил поведения, и
- использования результатов этого обучения для организация поведения, посредством постановки и достижения целей и решения связанных с этим задач.

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 , включающим соотношения v_{ij} , поступает некоторый объект O^t либо из входного анализатора, либо из ассоциативной памяти. (В общем случае в качестве объектов внимания могут использоваться различные понятия - предметы, соотношения, цели, задачи и пр.)

Попав в поле внимания, объект O^t и вектор V^t поступают одновременно:

- во входной анализатор, в результате чего на его полях производится коррекция важности объектов O_i ,
- в ассоциативную память, где производится сопоставление O^t с каждым из O_j .

При выполнении критерия новизны объект O^t запоминается, а в соответствии с вектором V^t строятся его связи с другими объектами памяти, формирующие структурное представление ситуаций. Наблюдаемая картина, в зависимости от степени новизны присутствующих на ней объектов, может отражаться в памяти как

непосредственно - в терминах 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 основе обобщения и принятия решений лежит одна и та же процедура *ассоциации*, т.е. сопоставления определяемого последовательностью переключений внимания входного описания с частичными структурами памяти, в результате которой для этих структур:

б) вычисляется *величина ассоциации* - мера близости, интегрально учитывающая:

- близость векторов характеристик объектов входа и памяти;
- близость относительных преобразований реперов этих объектов;
- важность объектов.

а) строится *след ассоциации* - подмножество объектов, общих для входного и хранящегося в памяти описаний.

Для обеспечения ассоциаций каждому объекту памяти O_j , кроме его непосредственного описания, сопоставлен набор характеристик, значения которых вычисляются при каждом переключении внимания:

- близость $r_j^t = r(O_j, O^t)$ к объекту внимания, определяющая принадлежность следу;
- близости $q_k^t = q(V_k, V^t)$ векторов отношений с соседними по связям объектами O_k ,
- величина ассоциации $a_j^t = \max_k (\theta, a_j^{t-1} - c, q_k^t a_k^t + r_j^t)$, ($c \ll 1$), 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.

Обобщение хранящихся в памяти описаний и выделение частичных структур объектов базируется на процедуре *ассоциативной кластеризации*. В ее основе лежит итеративное увеличение весов объектов, принадлежащих следам ассоциаций, пропорциональное величинам ассоциации описаний и важностям объектов и может интерпретироваться, как формирование частот совместного выполнения тех или иных наборов объектов.

Литература

1. Вайнцвайг М.Н. Обучающаяся система искусственного интеллекта с

- ассоциативной памятью // Вычислительные машины и искусственный интеллект, N2. Братислава. 1982.
2. Богоцкая Н.В., Вайнцвайг М.Н., Диментман А.М., Лосев И.С. Ассоциативные алгоритмы обобщения // Изв.АН СССР. Техн. кибернетика N1. 1985.
 3. Вайнцвайг М.Н., Полякова М.П. Механизм мышления и моделирование его работы в реальном времени //Сб. Интеллектуальные процессы и их моделирование. М. Наука. 1987
 4. Вайнцвайг М.Н., Полякова М.П. Архитектура мыслящей системы и нейронные сети. Сб. Интеллектуальные процессы и их моделирование. Информационные сети. ИППИ РАН, Москва. 1994, с. 132-151.
 5. Вайнцвайг М.Н., Полякова М.П. Модель системы автономного поведения. Новости искусственного интеллекта. Переславль-Залесский. 1994, N4, с.91-100.
 6. Вайнцвайг М.Н., Полякова М.П. О моделировании мышления // Сб. Проблемы управления и моделирования в сложных системах. Труды III Международной конференции. С 605-610 . Самара. 2003

Корректные алгоритмы в алгебраическом расширении одной П-модели алгоритмов классификации

О.М. Васильев

(Москва)

Введение. Постановка задачи

В работе рассматривается общая постановка задачи классификации на основании прецедентной информации. Все построения проводятся в рамках *алгебраического подхода*, описанного в [1] и [2].

Требуется синтезировать *алгоритмы* A (элементы некоторого множества M , называемого *моделью алгоритмов*), реализующие отображения из *пространства начальных информации* $I_i = R^n$ в *пространство финальных информации* $I_f = \{K_1, K_2, \Delta\}$ на основании *прецедентной информации* $\{x_k, y_k\}_{k=1}^q \subset I_i \times (I_f \setminus \{\Delta\})$. Изначально предполагается, что классы K_1 и K_2 в ней представлены.

Оптимальным в смысле количества ошибок на обучении назовём $A^* = \arg \min_{A \in M} \sum_{k=1, q: A(x_k) \neq y_k} 1$. В случае, если рассматриваемая сумма равна 0, алгоритм A^* также называют *корректным*.

Модель алгоритмов

Модели типа потенциальных функций (или *П-модели*) – условное

название класса моделей алгоритмов, использующих заимствованную из физики идею потенциала. Каждый прецедент мыслится как источник потенциального поля, при этом прецедентам класса K_1 приписываются положительные точечные заряды, а прецедентам класса K_2 – отрицательные. Решение о принадлежности точки пространства начальных информации тому или иному классу принимается в зависимости от знака суперпозиции полей всех прецедентов.

Определение. Потенциальная функция $K : I_i^2 \rightarrow R_+$ – произвольная всюду положительная убывающая функция расстояния (например, $K(u, v) = e^{-\alpha^2 d^2(u, v)}$, где $d : I_i^2 \rightarrow R_+$ – некоторая метрика).

Поле, возбуждаемое прецедентами класса K_1 , обозначим как Γ_+ :

$$\forall u \in I_i : \Gamma_+(u) = \sum_{k=1, q, y_k=K_1} K(x_k, u).$$

Поле, возбуждаемое прецедентами класса K_2 , обозначим как Γ_- :

$$\forall u \in I_i : \Gamma_-(u) = - \sum_{k=1, q, y_k=K_2} K(x_k, u).$$

Рассматриваемую модель алгоритмов определяют:
пространство оценок

$$I_e = R^2,$$

модель алгоритмических операторов

$$M_0 = \{B : I_i \rightarrow I_e \mid B(u) = (a\Gamma_+(u), b\Gamma_-(u)), \forall u \in I_i, a, b \in R_+\}$$

и *модель решающих правил* M_1 , составленная из единственного р. п.

$$C(\gamma_+, \gamma_-) = \begin{cases} K_1, \gamma_+ + \gamma_- > 0 \\ \Delta, \gamma_+ + \gamma_- = 0 \\ K_2, \gamma_+ + \gamma_- < 0 \end{cases}, \forall (\gamma_+, \gamma_-) \in I_e.$$

Теорема 1. В модели алгоритмов $M = M_1 \circ M_0$ существует оптимальный, в смысле количества ошибок на обучении, алгоритм A^* . Процесс построения A^* имеет линейную сложность относительно q .

Алгебраическое расширение модели

Определение. Назовём *минимизатором модуля* p -местную

корректирующую операцию на пространстве оценок I_e

$$ABS\text{MIN}_p((\gamma_+^1, \gamma_-^1), \dots, (\gamma_+^p, \gamma_-^p)) = \arg \min_{(\gamma_+, \gamma_-) \in \{(\gamma_+^1, \gamma_-^1), \dots, (\gamma_+^p, \gamma_-^p)\}} |\gamma_+ + \gamma_-|,$$

$$\forall ((\gamma_+^1, \gamma_-^1), \dots, (\gamma_+^p, \gamma_-^p)) \in I_e^p.$$

Рассмотрим алгебраическое расширение описанной модели алгоритмов M при помощи семейства корректирующих операций F , составленного из минимизаторов модуля всех натуральных арностей:

$$F = \bigcup_{p=1}^{\infty} \{ABS\text{MIN}_p\}.$$

Алгебраическое расширение исходной модели алгоритмов:

$$F[M] = \{A : I_i \rightarrow I_f \mid A = C \circ ABS\text{MIN}_p(B_1, \dots, B_p), p \in N, (B_1, \dots, B_p) \in M_0^p\}.$$

Теорема. Для того чтобы в $F[M]$ существовал корректный алгоритм необходимо и достаточно, чтобы функция потенциального отношения

$$\xi(u) = \frac{\Gamma_+(u)}{\Gamma_-(u)}, \forall u \in I_i$$

не принимала двух одинаковых значений для

$$\text{прецедентов} \quad \text{разных} \quad \text{классов,} \quad \text{т.е.}$$

$$\forall i, j \in \overline{1, q} : \xi(x_i) = \xi(x_j) \Rightarrow y_i = y_j.$$

Доказательство теоремы попутно обосновывает корректность следующего построения оптимального в смысле количества ошибок на обучении алгоритма.

Процесс построения оптимального алгоритма в расширенной модели

Рассмотрим отношение эквивалентности \mathcal{E} на I_i :

$$\forall u, v \in I_i : u \mathcal{E} v \leftrightarrow \xi(u) = \xi(v).$$

Обучение распадается на классы эквивалентности K_1, \dots, K_r по \mathcal{E} .

Для каждого $k := 1..r$ строим алгоритмический оператор B_k^* , выставляющий объектам из прецедентной информации принадлежащим K_k оценки, модуль суммы компонент которых не больше 1, а всем остальным прецедентам оценки, модуль суммы компонент которых не меньше $1+t$. При этом оператор B_k^* наилучшим образом

классифицирует прецеденты объекты прецедентной информации принадлежащие K_k . Явный вид «оптимального» алгоритмического оператора получен, но не приводится здесь ввиду громоздкости формул. Применение к совокупности «оптимальных» алгоритмических операторов, обладающих описанными свойствами, корректирующей операции $ABSMIN_r$, даёт оптимальный в смысле количества ошибок на обучении алгоритм.

Работа выполнена при поддержке гранта РФФИ 04-01-00161 и стипендии компании *Intel Technologies, Inc.*

Литература

1. Журавлёв Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики, 1978, N33, С. 5-68.
2. Рудаков К.В. Алгебраическая теория универсальных и локальных ограничений для алгоритмов распознавания // Москва, 1992.

Об использовании методов Boosting в задачах генерации знаний

Д.П. Ветров, Д.А. Кропотов
(Москва)

Введение

Для решения проблемы переобучения алгоритмов распознавания образов традиционные подходы, такие как статистическая теория Вапника-Червоненкиса, Байесовская теория обучения, принципы устойчивости и максимального зазора, предлагают выбирать модель оптимальной сложности. Такая модель, с одной стороны, содержит классификатор, способный распознавать обучающую выборку с высокой точностью, а с другой стороны, сложность алгоритмов модели в определенном смысле минимальна. Введение ограничений на сложность классификатора снижает риск переобучения параметров алгоритма на обучающую выборку прецедентов. Однако, предложенная в середине 90-х годов технология бустинга (boosting) [1] изменила представление исследователей о способах получения эффективных классификаторов. Несмотря на то, что бустинг приводит к росту сложности модели алгоритмов, способность к обобщению классификаторов возрастает. Таким образом, на первый план выходит не сама модель алгоритмов, а конкретный способ выбора классификатора внутри семейства [4].

Для решения задач анализа данных широкое распространение получили методы, основанные на поиске закономерностей. Среди них особенно эффективными при решении прикладных задач оказались

методы, основанные на построении закономерностей самого простого вида. Можно отметить методы бинарных решающих деревьев, статистически взвешенных синдромов, логических закономерностей. Согласно [2] среди всех методов распознавания наиболее эффективным в среднем при решении произвольной прикладной задачи является метод построения бинарных решающих деревьев C4.5 с применением бустинга.

Целью данного исследования было применение технологии бустинга к алгоритму распознавания по методу эффективных сужений [3]. Данный классификатор основан на построении набора закономерностей минимальной сложности. Его основной недостаток заключается в том, что границы разбиения допустимых диапазонов изменений значений признаков заранее фиксируются, и оптимизация по ним не проводится. Использование бустинга позволяет преодолеть этот недостаток.

Описание метода эффективных сужений

Рассмотрим стандартную задачу классификации объектов из R^n на l непересекающихся классов. Обучающую выборку обозначим $\{(x_i, y_i)\}_{i=1}^m$. Предположим, что каждый признак разбит на s (обычно 3-7) интервалов $\{A_{i,1}, \dots, A_{i,s}\}_{i=1}^n$. Метод эффективных сужений строит систему логических правил вывода вида «ЕСЛИ $x_i \in Sam(R)$, ТО $y_i \in Res(R)$ », объединяя в посылке ($Sam(R)$) с помощью конъюнкции предикаты «Признак № i лежит в интервале $A_{i,i}$ ». Количество таких предикатов в посылке назовем размерностью правила. Следствия правила ($Res(R)$) в нашем случае представляют утверждения о принадлежности объекта к одному из классов. Для определения меры качества правила используются понятия эффективности и репрезентативности. Под репрезентативностью понимается доля объектов, удовлетворяющих посылке правила, т.е. $rep(R) = \frac{1}{m} \sum_{i=1}^m 1\{x_i \in Sam(R)\}$, а под эффективностью – доля объектов из посылки правила, удовлетворяющих следствию правила: $eff(R) = \frac{1}{rep(R)m} \sum_{x_i \in Sam(R)} 1\{(x_i, y_i) \in Res(R)\}$.

Естественно предположить, что правило содержит значимые закономерности о природе данных (является допустимым), если оно обладает высокими репрезентативностью и эффективностью относительно обучающей выборки. Метод эффективных сужений последовательно находит все возможные допустимые правила наименьшего порядка (т.е. с наибольшей обобщающей способностью). При этом порог эффективности

зависит от величины репрезентативности правила (т.е. чем меньше объектов лежит в посылке правила, тем большей «контрастности» классов мы требуем). За счет ограниченного количества интервалов разбиений при небольших s удается осуществить последовательный перебор потенциально допустимых правил за разумное время. Следует, однако, отметить, что выбор разбиения признаков не рассматривается.

Применение бустинга к методу эффективных сужений

Авторами бустинга было предложено несколько различных вариантов алгоритмов. Наиболее эффективным среди них оказался алгоритм AdaBoost.M1 [1], который мы и будем использовать. Формально алгоритм применения бустинга к методу эффективных сужений выглядит следующим образом:

Шаг 1. Веса объектов выбираются исходя из равномерного распределения, т.е. $w_i = \frac{1}{m}, i = 1, \dots, m$

Шаг 2. С учетом распределения весов объектов диапазоны изменений значений признаков при помощи специальной процедуры разбиваются на заданное число множеств s (обычно 3-7).

Шаг 3. Производится обучение метода эффективных сужений $F(x)$ с учетом полученных разбиений значений признаков. При этом формулы для репрезентативности и эффективности учитывают распределение весов объектов, т.е.

$$rep(R) = \frac{\sum_{i=1}^m w_i 1\{x_i \in Sam(R)\}}{\sum_{i=1}^m w_i}, \quad eff(R) = \frac{\sum_{x_i \in Sam(R)} w_i 1\{(x_i, y_i) \in Res(R)\}}{\sum_{x_i \in Sam(R)} w_i}$$

Шаг 4. Вычисляется ошибка полученного классификатора

$$Error = \frac{\sum_{i=1}^m w_i 1\{y_i \neq F(x_i)\}}{\sum_{i=1}^m w_i} \text{ и его вес } \alpha = \log((1 - Error) / Error).$$

Затем веса неправильно распознанных объектов корректируются: $w_i^{new} = w_i^{old} \exp(\alpha \cdot 1\{y_i \neq F(x_i)\})$.

Шаг 5. Итоговый классификатор представляет собой взвешенное голосование по отдельным алгоритмам, т.е. $F(x) = \sum_{i=1}^q \alpha_i F_i(x)$. Если точность очередного алгоритма меньше 50% или точность итогового классификатора близка к 100%, то стоп, иначе перейти к шагу 2.

В качестве процедуры разбиения значений отдельных признаков использовались процедура разбиения по равномерной массе (т.е. в каждой группе суммарный вес выбирается примерно одинаковым), а также

процедура k -средних, учитывающая распределение весов объектов.

Итак, при применении бустинга к методу эффективных сужений предикаты правил (закономерностей) выбираются таким образом, чтобы сосредоточить внимание алгоритма на объектах, неправильно распознанных на очередной итерации.

Проведенные эксперименты на прикладных задачах подтверждают, что с ростом числа итераций бустинга точность нового алгоритма возрастает как на обучающей, так и на тестовой выборках.

Литература

1. Schapire R.E., The boosting approach to machine learning: An overview // MSRI Workshop on Nonlinear Estimation and Classification, 2002.
2. Friedman J., Hastie T., Tibshirani.R. The Elements of Statistical Learning. Springer, 2001.
3. Kropotov D.A., Vetrov D.P. An Algorithm for Rule Generation in Fuzzy Expert Systems // Proc. of 17th International Conference of Pattern Recognition, 2004
4. Воронцов К.В. Обзор современных исследований по проблеме качества обучения алгоритмов // Таврический вестник информатики и математики, 2004

Использование принципа наибольшего основания для автоматического выбора ядровой функции

Д.П. Ветров, Д.А. Кропотов, Н.О. Пташко
(Москва)

Введение

Метод опорных векторов (SVM) относится к числу наиболее распространенных и успешных методов решения задачи распознавания образов [1]. Одной из открытых на сегодняшний день проблем, возникающих при обучении SVM, является выбор внутренних параметров алгоритма, т.е. таких параметров, которые задает сам пользователь, и которые не изменяются при обучении. Целью данной работы является разработка метода, позволяющего, используя Байесовскую регуляризацию и принцип наибольшего основания [3], автоматически подбирать значения всех параметров метода опорных векторов. Его построение мы будем производить на базе уже существующего метода релевантных векторов (RVM), предложенного в работе [2].

Байесовская регуляризация и принцип наибольшего основания

Назовем моделью множество алгоритмов распознавания с фиксированным набором параметров алгоритма ω и их априорными распределениями. Пусть $W(\alpha), \alpha \in A$ - множество моделей, причем α определяет семейство алгоритмов, структуру их параметров ω и их

априорные распределения $P(\omega | \alpha)$. Обозначим правдоподобие обучающей выборки как $P(D_{train} | \omega)$. Используя принцип максимума правдоподобия для выбора наилучшей модели, получим известный принцип наибольшего основания (maximal evidence, подробнее см. доклад «О связи Байесовской регуляризации с устойчивостью алгоритмов распознавания» настоящего сборника).

$$P(D_{train} | \alpha) = \int_{W(\alpha)} P(D_{train} | \omega) P(\omega | \alpha) d\omega \rightarrow \max_{\alpha}$$

Байесовская регуляризация метода опорных векторов

Применение Байесовской регуляризации для решения поставленной задачи состоит в следующем. Внешние параметры SVM играют роль параметров модели. Таким образом, мы подбираем самую правдоподобную модель.

SVM основывает свои предсказания на функциях вида

$$t(\mathbf{x}^*; \omega) = \text{sign} \left(\sum_{i=1}^N \omega_i K(\mathbf{x}^*, \mathbf{x}_i) + \omega_0 \right) \quad (\text{здесь и далее}$$

$D_{train} = \{(\mathbf{x}_i, t_i)\}_{i=1}^N$, где $\mathbf{x}_i \in R^d$, $t_i \in \{-1, 1\}$, $i = 1, \dots, N$). При этом веса объектов $\{\omega_i\}_{i=1}^N$ неотрицательны и ограничены сверху константой $C > 0$. Ядровая функция $K(\mathbf{x}, \mathbf{y})$ также имеет параметры, от которых существенно зависит качество получаемых классификаторов. В RVM веса ядровых функций $\{\omega_i\}_{i=1}^N$ трактуются как случайные величины с априорным нормальным распределением $N(0, \alpha_i^{-1})$. Коэффициенты α_i подбираются путем максимизации величины evidence.

Используя Байесовскую регуляризацию, метод RVM успешно справляется с необходимостью устанавливать значение C , при этом функция $K(\mathbf{x}, \mathbf{y})$ считается заданной априори. Рассмотрим наиболее

популярный вид функции $K(\mathbf{x}, \mathbf{y}) = e^{-\|\mathbf{x}-\mathbf{y}\|^2/2\sigma^2}$. Здесь параметр σ играет роль «ширины» гауссианы. Прямое использование метода релевантных векторов для подбора значения σ оказывается неприемлемым. Определяя модель просто как множество функций

$$\sum_{i=1}^N \omega_i K(\mathbf{x}^*, \mathbf{x}_i) + \omega_0 \text{ с фиксированным значением } \sigma,$$

получим, что наиболее правдоподобной будет модель с наименьшим возможным значением σ . В то же время очевидно, что классификаторы с «узкими»

гауссианами чрезвычайно чувствительны даже к небольшому смещению начальных данных, что является свидетельством их неустойчивости и плохой обобщающей способности. Для учета этого отрицательного эффекта предлагается включить координаты центров гауссиан в параметры классификаторов. Формально модель может быть определена как множество классификаторов вида

$$t^*(\mathbf{x}^*; \omega, Z) = \text{sign}(y(\mathbf{x}^*; \omega, Z)) = \text{sign}\left(\sum_{i=1}^M \omega_i K(\mathbf{x}^*, \mathbf{z}_i) + \omega_0\right),$$

где $Z = \{\mathbf{z}_1, \dots, \mathbf{z}_M\} \subset \mathbb{R}^d$, $p(\omega | \alpha) = \prod_{i=0}^M N(\omega_i | 0, \alpha_i^{-1})$.

Описание алгоритма и выводы

Введем правдоподобие выборки следующим образом:

$$P(D_{train} | \omega, Z, \sigma) = \prod_{i=1}^N 1/(1 + \exp(-\lambda t_i f(\mathbf{x}_i))), \quad f(\mathbf{x}_i) = y(\mathbf{x}_i; \omega, Z).$$

Для проведения Байесовской регуляризации необходимо максимизировать evidence. Для этого воспользуемся аппроксимацией Лапласа.

$$E(\alpha, \sigma) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} P(D_{train} | \omega, Z, \sigma) P(\omega | \alpha) d\omega dZ \approx$$

$$P(D_{train} | \omega_{max}, Z_{max}, \sigma) P(\omega_{max} | \alpha) \frac{1}{\sqrt{|-H_Z| | -H_\omega|}} Const,$$

где (ω_{max}, Z_{max}) - точка максимума логарифма подынтегральной функции, а H_Z, H_ω -соответствующие гессианы в этой точке. Гессиан H_Z представляется трудным для вычислений в силу своего размера, поэтому при вычислении предлагается дифференцировать функцию не по каждой координате каждого центра, а формально по целому вектору, считая его единой переменной, т.е.

$$\frac{\partial^2 f(\mathbf{x}_k)}{\partial^2 \mathbf{z}_i} \equiv \omega_k \left[\frac{\|\mathbf{z}_i - \mathbf{x}_k\|^2}{\sigma^4} - \frac{1}{\sigma^2} \right] K(\mathbf{z}_i, \mathbf{x}_k).$$

Таким образом, применяя покоординатный спуск, удастся решить задачу оценки и оптимизации $E(\alpha, \sigma)$. Результатом распознавания тестовой выборки D_{test} является такая конфигурация меток классов,

которая обеспечивает максимум величине

$$P(D_{test} | D_{train}) = P(D_{test} | \omega_{max}, Z_{max}, \sigma_{ME}),$$
где $(\omega_{max}, Z_{max}) = \arg \max P(D_{train} | \omega, Z, \sigma_{ME})P(\omega | \alpha_{ME})$, а
 $(\alpha_{ME}, \sigma_{ME}) = \arg \max E(\alpha, \sigma)$.

Разработанный метод подбора ядровой функции показал более высокое качество работы по сравнению с аналогичной процедурой с использованием скользящего контроля и, как правило, приводил к более разреженным (т.е. использующим меньше ядровых функций) алгоритмам.

Работа выполнена при поддержке РФФИ (гранты 05-07-90333, 04-01-08045, 04-01-00161, 03-01-00580) и ИНТАС (YS 04-83-2942).

Литература

1. Vapnik V. The Nature of Statistical Learning Theory, Springer-Verlag, New-York, 1995
2. Tipping M. E. Relevance Vector Machines // Advances in Neural Information Processing Systems, 12, MIT Press, 2000, pp. 652-658
3. MacCay D.J.C. Information Theory, Inference, and Learning Algorithms, Cambridge University Press, 2003

О связи Байесовской регуляризации с устойчивостью алгоритмов распознавания

Д.П. Ветров, Д.А. Кропотов, Н.О. Пташко

(Москва)

Введение

Хорошо известно, что задача машинного обучения по прецедентам является некорректно поставленной. Восстановление функции непрерывных, в общем случае, переменных по конечному набору точек приводит к континууму допустимых решений, обладающих разным качеством с точки зрения обработки новых объектов (различной обобщающей способностью) и является причиной перенастройки (overfitting) алгоритмов распознавания. Естественным способом улучшения обобщающей способности является минимизация ошибок на валидационной выборке или при скользящем контроле. Однако, оба этих способа не всегда приемлемы в силу значительных вычислительных или информационных затрат. Кроме того, такие оценки обладают значительной дисперсией и их оптимизация, вообще говоря, не гарантирует получения наилучшего алгоритма распознавания.

Другим возможным способом улучшения обобщающей способности является искусственное сужение области поиска решения заданием ограничений или введением штрафных функций. Такой подход получил название регуляризации машинного обучения. В общем виде схема

регуляризации представляет замену исходного функционала качества, связанного с ошибкой на обучающей выборке, регуляризованным функционалом

$$\psi(w, \lambda) = \varphi(w) + R(w, \lambda)$$

причем $\lim_{\lambda \rightarrow 0} R(w, \lambda) = 0$.

В этом случае, при обучении нет необходимости привлекать независимую валидационную выборку или проводить процедуру скользящего контроля. На сегодняшний день известно множество различных процедур регуляризации для тех или иных семейств алгоритмов распознавания [4]. Ключевой проблемой при регуляризации является выбор значения параметра регуляризации λ . Регуляризатор $R(w, \lambda)$, обычно штрафующий те или иные особенности алгоритма, которых пользователь хотел бы избежать, оперирует в других терминах относительно функционала $\varphi(w)$, поэтому их прямое сравнение требует тщательного выбора параметра λ . Как правило, такой выбор осуществляется эвристически либо с использованием валидационной выборки или скользящего контроля.

Общие принципы регуляризации

На сегодняшний день известны, по крайней мере, три общие процедуры регуляризации, применимые к достаточно широкому кругу алгоритмических семейств. Наиболее известная из них – структурная минимизация риска Вапника-Червоненкиса [1], опирающаяся на понятие емкости классификатора. При ее использовании предпочтение отдается наименее «гибким» классификаторам, обеспечивающим приемлемую точность на обучении. Другой процедурой является принцип минимальной длины описания (Minimal Description Length) [2], выражающий точность на обучении и алгоритмическую сложность классификаторов в терминах длины закодированного сообщения. Более простые классификаторы являются предпочтительными. Наконец, третьей известной процедурой, получившей развитие в мире в последнее время, является т.н. Байесовская регуляризация [3].

Принцип наибольшего основания

В дальнейшем будем считать, что рассматриваемые семейства классификаторов оперируют в вероятностных терминах или, по крайней мере, допускают адекватную вероятностную трактовку. В этом случае классический подход к машинному обучению состоит в применении принципа наибольшего правдоподобия, т.е. классификации новых данных по результатам обучения как $P(D_{test} | D_{train}) = P(D_{test} | w_{ML})$, где w_{ML} - параметр алгоритма, обращающий в максимум правдоподобие обучающей

выборки $P(D_{train} | w)$. При наличии нескольких конкурирующих моделей (семейств алгоритмов распознавания) W_1, \dots, W_p предпочтение отдается той модели, в которой правдоподобие обучающей выборки было наибольшим. Очевидно, что прямое применение такого подхода чревато получением перенастроенного решения. Введем априорные распределения $p(w | \alpha)$ параметров алгоритма w в модели $W(\alpha)$. Применим принцип максимума правдоподобия для выбора подходящей модели

$$\alpha_{ML} = \arg \max P(D_{train} | \alpha) = \arg \max_{W(\alpha)} \int P(D_{train} | w) P(w | \alpha) dw$$

Величина $P(D_{train} | \alpha)$ называется основанием (evidence) модели. При этом распознавание новых данных формально может быть записано как

$$P(D_{test} | D_{train}) = \int_{W(\alpha_{ML})} P(D_{test} | w) P(w | D_{train}, \alpha_{ML}) dw \approx P(D_{test} | w_{MP}(\alpha_{ML})),$$

где $w_{MP}(\alpha) = \arg \max P(D_{train} | w) P(w | \alpha)$.

Аппроксимация evidence

Подсчет величины основания является, вообще говоря, нетривиальной задачей. Однако, на самом деле, основной интерес представляет не поведение различных классификаторов модели при всех возможных значениях параметров, а лишь локальное поведение подынтегральной функции в окрестностях точки максимума. Наличие других максимумов не должно играть роли при выборе модели, так как они не оказывают никакого влияния на классификацию и обобщающую способность. В этой связи предлагается использовать аппроксимацию Лапласа (замену логарифма подынтегральной функции первыми тремя членами его разложения в ряд Тэйлора в точке максимума) не только при регуляризации линейных моделей (например, линейной ядерной регрессии или метода релевантных векторов), но и в случае многоэкстремальных функций. В этом случае значение основания модели может быть приближенно записано как

$$E(\alpha) \approx (2\pi)^{N/2} P(D_{train} | w_{MP}(\alpha)) P(w_{MP}(\alpha) | \alpha) \det^{-1/2}(-H_{ww}(w_{MP}(\alpha)))$$

где $H_{ww}(w_{MP}(\alpha)) = \nabla_w \nabla_w \ln(P(D_{train} | w) P(w | \alpha))|_{w=w_{MP}(\alpha)}$, а N -

количество параметров алгоритма. Предлагаемый подход позволяет выразить в единых терминах точность и устойчивость классификатора по отношению к изменению параметров алгоритма. Это, в свою очередь, дает возможность обеспечить компромисс между этими двумя понятиями. Представляется разумным требовать от алгоритма, обеспечивающего

приемлемую точность на обучении, максимальной устойчивости, а не минимальной сложности или «гибкости». В данном случае, Байесовская регуляризация является в некотором смысле обоснованием полученного соотношения точность/устойчивость.

Предложенный подход был успешно применен для задачи подбора наилучшей потенциальной функции в ядровых методах (см. доклад «Использование принципа наибольшего основания для автоматического выбора ядровой функции» настоящего сборника).

Работа выполнена при поддержке РФФИ (гранты 05-07-90333, 04-01-08045, 04-01-00161, 03-01-00580) и ИНТАС (YS 04-83-2942).

Литература

1. Vapnik V. The Nature of Statistical Learning Theory, Springer-Verlag, New-York, 1995
2. Gruenwald P. A Tutorial Introduction to the Minimum Description Length Principle // Advances in Minimum Description Length: Theory and Applications. MIT Press, 2004
3. MacCay D.J.C. Information Theory, Inference, and Learning Algorithms, Cambridge University Press, 2003
4. Bishop C.M. Neural Networks for Pattern Recognition, Oxford University Press, 1995

Применение принципа минимальной длины описания для обрезания бинарных решающих деревьев

Д.П. Ветров, Д.А. Кропотов, И.В. Толстов

(Москва)

Введение

Одной из ключевых проблем, возникающих при построении алгоритмов распознавания образов, является проблема переобучения, т.е. слишком точная настройка методов на обучающую выборку, которая ведет к плохому качеству распознавания тестовой выборки. В методе бинарных решающих деревьев процесс обучения (ветвление дерева) продолжается до тех пор, пока в каждом листе дерева объекты не будут принадлежать только одному классу (если не вводить дополнительные критерии остановки). Построенное таким образом дерево назовем *полным*. Для решения проблемы переобучения разработаны различные методы остановки ветвления раньше достижения нулевого уровня ошибки на обучающей выборке, а также методы обрезания (pruning) полного дерева [1]. В настоящий момент ни один из методов обрезания дерева не является универсальным для всех типов задач.

Целью данной работы было исследование применения принципа минимальной длины описания (MDL) для обрезания бинарных решающих деревьев. Также проведено сравнение на тестовых задачах 5 различных

методов обрезания [1]: REP (Reduced Error Pruning), PEP (Pessimistic Error Pruning), MEP (Minimum Error Pruning), CCP (Cost-Complexity Pruning) и MDLP (Minimum Description Length Pruning).

Minimum Description Length Pruning (MDLP)

Общее описание принципа минимальной длины описания можно найти, например, в [2]. При использовании метода бинарных решающих деревьев, длину описания можно оценить следующим образом:

$$D_O = D_{err} + D_{tree}$$

$$D_{err} = mP_{train}(\log m + \log l)$$

$$D_{tree} = \frac{N-1}{2}(2 \log m + \log n + 2 \log N) + \frac{N+1}{2} \log l$$

где D_{tree} - длина описания дерева, построенного по обучающей выборке;

D_{err} - длина описания объектов, неправильно распознанных этим деревом;

P_{train} - доля неправильно распознанных объектов; n - число признаков;

N - число вершин дерева; m - число объектов в обучающей выборке, а l - число классов. Для кодирования неправильно распознанных объектов используются номер объекта в обучающей выборке и его метка класса.

При кодировании решающего дерева по-разному представляются листья и внутренние вершины. Для описания листа нам достаточно указать метку класса. А чтобы полностью описать внутреннюю вершину, необходимо указать номер признака, значение порога (в качестве порогового значения берется среднее арифметическое значений 2-х объектов по данному признаку, поэтому используются номера 2-х объектов), а также указатели на две дочерние вершины (их номера в массиве вершин дерева).

При построении (последовательном ветвлении) дерева удобно вычислять длину описания дерева рекурсивно, т.к. при очередном ветвлении добавляется 1 лист и 1 внутренняя вершина:

$$D_{tree}(t) = D_{tree}(t-1) + 2 \log m + \log n + 2 \log N + \log l$$

При распознавании по принципу минимальной длины описания используется дерево, для которого достигается минимум длины описания среди всех деревьев, получаемых на различных итерациях ветвления.

Сравнение результатов работы методов обрезания

Для проведения исследования были выбраны 4 известные задачи классификации, взятые из хранилища UCI [3]: “Cleveland”, “LongBeach”, “Hungary”, “Switzerland”. Это данные по четырем клиникам о сердечных

заболеваниях. Для построения полного дерева каждый раз использовался алгоритм C4.5 [4]. Для оценки качества распознавания методов была выбрана следующая стратегия проведения эксперимента. Для каждой задачи все множество объектов 20 раз случайным образом разбивалось на обучающую и тестовую выборки так, чтобы в обучающую выборку попало примерно 70% объектов, а в тестовую, соответственно, около 30%. Таким образом, качество распознавания проверялось на независимой от объектов обучения выборке, а затем результат усреднялся для всех 20 подвыборок исходной задачи.

В таблице 1 представлена средняя доля ошибок вместе со стандартным отклонением на тестовой выборке при применении рассматриваемых методов обрезания полного дерева. Строка Full показывает минимум ошибки по деревьям, которые получались на различных этапах построения полного дерева. Методы REP и CCP, в отличие от методов MEP, PEP и MDLP, используют для обучения контрольную выборку (pruning set), поэтому для них полное дерево строилось не по всей обучающей выборке, а только по 70% объектов обучения. Строка Reduced отражает минимум ошибки при использовании поддеревьев дерева, построенного по редуцированной обучающей выборке.

Еще одной характеристикой, отражающей способность дерева к обобщению, является количество вершин. В таблице 2 приведены данные по числу вершин для методов обрезания, а также для полного дерева (Full) и дерева, построенного при использовании 70% обучающей выборки (Reduced).

Таблица 1. Доля ошибок на тестовой выборке (в процентах)

	Cleveland	Hungary	LongBeach	Switzerland
MEP	25.71±5.22	20.11±3.24	27.35±2.68	7.89±0
PEP	21.69±3.14	20.23±3.22	26.23±0	7.89±0
MDLP	22.12±4.36	20.11±2.85	27.61±2.69	7.89±0
Full	18.91±2.67	17.53±3.69	23.12±4.86	7.89±0.59
REP	23.42±3.93	29.10±8.15	29.34±4.82	8.42±1.62
CCP	26.20±5.25	22.02±4.31	35.12±6.98	14.08±6.23
Reduced	19.84±3.76	17.75±3	25.45±4.03	7.78±2.5

Таблица 2. Число вершин в дереве

	Cleveland	Hungary	LongBeach	Switzerland
MEP	6.7±6.94	5.6±3.84	2.6±3.24	1±0
PEP	21.8±6.3	7.8±3.97	1±0	1±0
MDLP	11±2.25	4.9±1.77	1.84±1.38	1±0
CCP	22.4±10.36	47±26.6	159±66.27	14.3±3.85
Reduced	45.9±5.33	70.7±19.55	163.8±64.1	14.6±2.5
Full	69.1±4.79	103.9±22.02	304±113.8	19.6±3.62

Заключение

Таким образом, рассмотренный метод обрезания MDLP показал хорошие результаты на различных задачах по доле ошибок на тестовой выборке, и выбирает относительно небольшие поддеревья, что, по-видимому, предохраняет обрезанное решающее дерево от существенного переобучения.

Этот метод можно применять для обрезания решающего дерева наравне с другими известными методами pruning, а для многих задач с большим успехом.

Работа выполнена при поддержке грантов РФФИ (№03-01-00580, №04-01-08045, 05-07-90333) и ИНТАС (YS 04-83-2942).

Литература

1. Esposito F., Malerba D., Semeraro G. A Comparative Analysis of Methods for Pruning Decision Trees // IEEE Trans. Pattern Analys. Mach. Intelligence, 1997. V.19. N.5. P.476-492
2. MacKay David J.C. Information Theory, Inference, and Learning Algorithms // Cambridge University Press 2003. P.352-353
3. Murphy P., Aha D. UCI repository of machine learning databases // Univ. California, Dept. Informat. and Comput. Sci., Irvine, Calif., 1996.
4. Quinlan J.R. C4.5: Programs for Machine Learning // San Mateo, Calif.: Morgan Kaufmann, 1993.

Расстояние на высказываниях экспертов и мера опровержимости (информативности) высказываний с помощью моделей некоторых теорий

А.А. Викентьев

(Новосибирск, Академгородок)

Введение

При анализе знаний, заданных в виде высказываний экспертов, для различия содержащейся в них информации и группирования их по схожести, возникает необходимость введения расстояния между высказываниями экспертов и меры опровержимости (информативности) высказываний экспертов. Этой проблемой занимались Загоруйко Н.Г., Лбов Г.С., Викентьев А.А. [1-4]. Хотим ввести подобное расстояние не на всем множестве моделей, а на моделях некоторой, заранее фиксированной теории Γ . Такой подход кажется естественным при изучении некоторой конкретной прикладной проблемы, (поскольку тогда расстояние и информативность не будут искажены моделями, не относящимися к изучаемой области) заданной например, некоторыми знаниями о ней, далее - теорией. Работа проделана в рамках проекта РФФИ 04-01-00858а. Мы фиксируем теорию Γ , суть, набор таких высказываний, например, с

которыми согласились все эксперты. Пусть $S(\Sigma) = \{v_1, \dots, v_n\}$ - набор элементарных высказываний. Теорией Γ назовем набор формул (- гипотез) $\{\varphi_1, \dots, \varphi_k\}$ - высказываний экспертов, с которыми все эксперты согласны. Предполагается, что теория Γ удовлетворяет следующим требованиям:

- 1) непротиворечивости (совместности);
- 2) замкнутости относительно выводимости (это требование не обязательно, но для полноты можно считать, что эксперты могут доказывать формулы с помощью гипотез);
- 3) устойчивости моделей Γ относительно пересечений или объединений.

Расстояние на высказываниях экспертов и его простейшие свойства

Пусть База Знаний Σ состоит из формул исчисления высказываний.

Определение 1. Множество элементарных высказываний $S(\Sigma) = \{v_1, \dots, v_n\}$, используемых для написания высказываний из Σ , назовем носителем совокупности знаний. Рассматриваем $P(S(\Sigma))$ -множество всевозможных подмножеств $S(\Sigma)$, его элементы, суть наборы $\{v_i \mid i \in I\}$, где $I \subseteq \{1, \dots, n\}$ истинностных значений элементарных высказываний, называем моделями. Мощность множества моделей исчисления высказываний равна $|P(S(\Sigma))| = 2^{|S(\Sigma)|}$.

Обозначим через $\text{Mod}\Gamma = \text{Mod}_{S(\Sigma)}\Gamma = \{M \in P(S(\Sigma)) \mid M \models \Gamma\}$ все модели теории Γ . Множество моделей из $\text{Mod}\Gamma$ на которых формула A – истинна, обозначим через $\text{Mod}_\Gamma(A)$.

Теорема 1. Для теорий Γ , устойчивых относительно объединений или пересечений справедливы следующие 9 свойств расстояния:

- 1) $0 \leq \rho_\Gamma(\varphi, \psi) \leq 1$; 2) $\rho_\Gamma(\varphi, \psi) = \rho_\Gamma(\psi, \varphi)$;
- 3) если $\varphi \equiv_\Gamma \psi$, то $\rho_\Gamma(\varphi, \psi) = 0$;
- 4) $\rho_\Gamma(\varphi, \psi) = 1 \Leftrightarrow \varphi \equiv_\Gamma \neg\psi$;
- 5) если $\varphi \equiv_\Gamma \varphi_1$ и $\psi \equiv_\Gamma \psi_1$, то $\rho_\Gamma(\varphi, \psi) = \rho_\Gamma(\varphi_1, \psi_1)$;
- 6) $\rho_\Gamma(\varphi, \psi) = 1 - \rho_\Gamma(\varphi, \neg\psi) = \rho_\Gamma(\neg\varphi, \neg\psi)$;
- 7) $\rho_\Gamma(\varphi, \psi) \leq \rho_\Gamma(\varphi, \chi) + \rho_\Gamma(\chi, \psi)$;
- 8) $\rho_\Gamma(\varphi, \neg\varphi) = \rho_\Gamma(\varphi, \psi) + \rho_\Gamma(\psi, \neg\varphi)$;
- 9) $\rho_\Gamma(\varphi, \psi) = \rho_\Gamma((\varphi \& \psi), (\varphi \vee \psi))$.

Доказательство аналогично [4] с использованием свойств теорий.

Мера опровержимости (информативности) высказываний

Определение 2. Мерой опровержимости высказывания φ назовем

относительное число моделей теории Γ на которых высказывание ложно. Для высказываний совместных с теорией определим меру информативности на множестве $Mod\Gamma$, как меру опровержимости высказывания φ .

$$\begin{aligned}\mu_{\Gamma}(\varphi) &= \rho_{\Gamma}(\varphi, \Gamma) = \frac{|Mod_{\Gamma}(\varphi \& \neg\Gamma) \cup Mod_{\Gamma}(\neg\varphi \& \Gamma)|}{|Mod\Gamma|} = \\ &= \frac{|Mod_{\Gamma}(\neg\varphi \& \Gamma)|}{|Mod\Gamma|} = \frac{|Mod_{\Gamma}(\neg\varphi)|}{|Mod\Gamma|}\end{aligned}$$

Теорема 2. Для теорий Γ , устойчивых относительно объединений или пересечений справедливы следующие 12 свойств меры опровержимости высказываний:

- 1) $0 \leq \mu_{\Gamma}(\varphi) \leq 1$;
- 2) $\mu_{\Gamma}(\neg\varphi) = 1 - \mu_{\Gamma}(\varphi)$;
- 3) $\mu_{\Gamma}(\varphi) \leq \mu_{\Gamma}(\varphi \& \psi)$;
- 4) $\mu_{\Gamma}(\varphi \vee \psi) \leq \mu_{\Gamma}(\varphi)$;
- 5) если $\rho_{\Gamma}(\varphi, \psi) = 1$, то $\mu_{\Gamma}(\varphi \& \psi) = 1$ и $\mu_{\Gamma}(\varphi \vee \psi) = 0$;
- 6) если $\rho_{\Gamma}(\varphi, \psi) = 0$, то

$$\mu_{\Gamma}(\varphi) = \mu_{\Gamma}(\psi) = \mu_{\Gamma}(\varphi \& \psi) = \mu_{\Gamma}(\varphi \vee \psi);$$

- 7) $\mu_{\Gamma}(\varphi \& \psi) = \rho_{\Gamma}(\varphi, \psi) + \mu_{\Gamma}(\varphi \vee \psi)$;

8)

$$\min\{\mu_{\Gamma}(\varphi), \mu_{\Gamma}(\psi)\} \geq \mu_{\Gamma}(\varphi \vee \psi) \geq \max\{\mu_{\Gamma}(\varphi), \mu_{\Gamma}(\psi)\} - \rho_{\Gamma}(\varphi, \psi) \text{ и}$$

$$\min\{\mu_{\Gamma}(\varphi), \mu_{\Gamma}(\psi)\} + \rho_{\Gamma}(\varphi, \psi) \geq \mu_{\Gamma}(\varphi \& \psi) \geq \max\{\mu_{\Gamma}(\varphi), \mu_{\Gamma}(\psi)\};$$

- 9) если $\mu_{\Gamma}(\varphi) = \mu_{\Gamma}(\varphi_1)$, $\mu_{\Gamma}(\psi) = \mu_{\Gamma}(\psi_1)$ и $\rho_{\Gamma}(\varphi, \psi) \leq \rho_{\Gamma}(\varphi_1, \psi_1)$, то $\mu_{\Gamma}(\varphi \& \psi) \leq \mu_{\Gamma}(\varphi_1 \& \psi_1)$;

- 10) если $\mu_{\Gamma}(\varphi) \leq \mu_{\Gamma}(\varphi_1)$, $\mu_{\Gamma}(\psi) = \mu_{\Gamma}(\psi_1)$ и $\rho_{\Gamma}(\varphi, \psi) = \rho_{\Gamma}(\varphi_1, \psi_1)$, то $\mu_{\Gamma}(\varphi \& \psi) \leq \mu_{\Gamma}(\varphi_1 \& \psi_1)$;

- 11) $\mu_{\Gamma}(\varphi \& \psi) = \frac{\mu_{\Gamma}(\varphi) + \mu_{\Gamma}(\psi) + \rho_{\Gamma}(\varphi, \psi)}{2}$;

- 12) $\mu_{\Gamma}(\varphi \vee \psi) = \frac{\mu_{\Gamma}(\varphi) + \mu_{\Gamma}(\psi) - \rho_{\Gamma}(\varphi, \psi)}{2}$.

Доказательство аналогично [4, 1] с использованием теоремы 1. Имеет место обобщение этих результатов на аналогичные теории первого порядка, с аналогичными свойствами. Теоремы усиливают результаты Ефимова Д.В.

Литература

1. Лбов Г.С., Старцева Н.Г. Логические решающие функции и вопросы статистической устойчивости решений. Новосибирск: Издательство Института математики, 1999. С. 85-102.
2. Загоруйко Н.Г., Бушуев М.В. Меры расстояния в пространстве знаний // Анализ данных в экспертных системах. Новосибирск, 1986. Выпуск 117: Вычислительные системы. С.24-35.
3. Викентьев А.А., Лбов Г.С. О метризации булевой алгебры предложений и информативности высказываний экспертов // Доклад РАН 1998. Т.361, №2 С.174-176.
4. Vikentiev A.A., Lbov G.S. Setting the metric and informativeness on statements of experts // Pattern Recognition and Image Analysis. 1997 V.7, N2, P.175-183.
5. Кейслер Г., Чэн Ч.Ч. Теория моделей. Москва: Мир, 1977.
6. Ершов Ю.Л., Палютин Е.А. Математическая логика. Санкт-Петербург, 2004.

Мультишкалы для приближенных симметрий в плотных упаковках кластеров

А.П. Виноградов, J. Voracek, Ю.И. Журавлев

(Москва-Lappeenranta)

В работе [1] исследовался подход к решению задачи построения плотных упаковок кластеров на произвольной выборке $X \subset R^N$ и поиска приближенных и точных симметрий упаковок, а также симметрий области X . Предложена схема последовательных испытаний, в которой для этих целей задействуются экстремальные свойства последовательного случайного выбора. Суть подхода состоит в использовании простых процедур и фиксированного объема памяти на протяжении длительного времени вместо трудоемкого прямого решения. Предложенная схема представляет собой комбинацию парzenовского оценивания плотности и преобразования Хоу, которое здесь выполняется каждый раз на многообразии какой-либо из групп непрерывных симметрий и настраивается на тот или иной тип смежного класса из ограниченного числа типов. Схема обладает достаточными эргодическими свойствами, что позволяет при возрастании количества испытаний все более надежно выявлять оптимальные и близкие к оптимальным варианты упаковок, отыскивать их приближенные и точные симметрии, а также симметрии

самой области X .

Система симметрий, выявляемых на данном пути, может оказаться сложной, поэтому важно исследовать различные средства, которые позволяли бы ориентироваться в ней. Ниже дается описание двух естественных мультишкал, пригодных для этой цели. В первой, представляющей возрастание надежности, полугрупповым параметром служит число испытаний. Во второй, связанной с интерпретацией результата, использована полугруппа операции \vee из стандартной решетки подгрупп в SO_N .

Пусть $X \subset R^N$ – ограниченная область. В схеме [1] для представления испытаний и обнаружения вариантов упаковок используется специальная структура вида $\mathcal{S} = m \times S$, объединяющая m экземпляров многообразия SO_N . Проявления приближенных симметрий обнаруживаются в слоях S в виде возрастных плотности реализаций на подмногообразиях смежных классов в SO_N , которые регистрируются при помощи преобразований Хоу. Пусть $\mu(M_1, K)$ – возникшее после M_1 испытаний эмпирическое распределение реализаций на многообразии некоторого смежного класса K , $G \subset SO_N$ – порождающая K подгруппа, и χ – типичная конфигурация кластеров, которую представляет слой в S . Если соответствующий кластер в параметрическом пространстве Хоу содержит заметную долю точек, то группа G отмечается как описывающая приближенную симметрию. Для любого M_1 в распределении $\mu(M_1, K)$ уже содержится результат, характеризующий серию из M_1 испытаний, но этот результат готов также к уточнению в ходе последующих испытаний. Для любых M, μ обозначим $U(M, \mu)$ операцию пополнения распределения μ в результате выполнения M дополнительных испытаний. Тогда, для любого набора чисел дополнительных испытаний M_i , $i=2,3,\dots,\max$, будет справедлива формула

$$U\left(\sum_{i=2} M_i, \mu(M_1, K)\right) = U(M_{\max}, U(M_{\max-1}, \dots, U(M_2, \mu(M_1, K)) \dots)), \quad (1)$$

которая представляет мультишкалу, описывающую для многообразия K динамику появления реализаций дополнительных серий испытаний.

Конечно, мультишкала имеет тривиальный смысл и характеризует лишь данную последовательность испытаний и лишь для данного смежного класса. В частности, изменить в (1) можно только вид набора серий M_i , $i=2,3,\dots$, но не очередность испытаний. Тем не менее, для усредненных значений можно определить на той же базе более содержательный объект, уже обладающий инвариантностью к

перестановкам. В самом деле, пусть теперь $\mu(M_1, K)$ – априорное распределение на K для выборки из M_1 испытаний. Тогда автоматически имеем

$$U(M_2, \mu(M_1, K)) = \mu(M_1 + M_2, K),$$

и формула (1) представляет теперь мультишкалу на многообразии K для априорной последовательности проявления симметрии G с типичной конфигурацией χ . Любая реализация тривиальной мультишкалы, которая выше была представлена первой, аппроксимирует эту последовательность тем точнее, чем больше проведено испытаний.

Второй пример касается поиска максимальных групп симметрии. Сгущения реализаций на слое в \mathcal{S} являются исходным объектом для выполнения преобразований Хоу. Настройкой преобразования определяются приоритеты в интерпретации сгущений как проявлений подмногообразий тех или иных смежных классов. Но те же сгущения покрываются, вообще говоря, многими возможными комбинациями подмногообразий смежных классов, быть может, менее плотно заполненными. Особенно затруднен выбор между подгруппами высоких размерностей, поэтому начинать следует с простых объектов, например, пар точек для дискретных поворотов на π или отрезков для SO_2 в непрерывном случае. Критерием отбора при поиске приближенных симметрий служит непрерывность заполнения орбит точками испытаний, а при поиске точных симметрий – однородность такого заполнения, и переход к исследованию смежных классов объемлющей подгруппы оправдан лишь в том случае, когда многие из смежных классов – частных случаев этой симметрии – выдерживают тест на непрерывность или однородность.

Пусть $G_1 \subset G_2 \subset \dots \subset G$ – некоторая последовательность подобных переходов. Мы работаем с конечными выборками, и результаты тестов могут показывать лишь степени непрерывности или однородности. Поэтому прохождение теста объемлющей группой становится также основанием для поиска в ее составе еще не исследованной подгруппы, смежные классы которой могут оказаться заполненными более гладко или более равномерно, чем эта максимальная на данный момент группа, выдержавшая тест на принадлежность к симметриям. Результат выбора по двум критериям – величине размерности и степени непрерывности (или однородности) заполнения орбиты – назовем группой максимальной симметрии. Пусть $G, G' \subset SO_N$. Обозначим $O(G', \text{inf}(G))$ операцию, состоящую в пополнении множества $\text{inf}(G)$ результатов тестов смежных классов по G на непрерывность (или однородность) результатами аналогичных тестов для всех подгрупп из $G \vee G'$, отличных от G . Тогда,

каковы бы ни были априорные предпочтения в интерпретации сгущений, определяющие траекторию поиска подгруппы максимальной симметрии $G_1 \subset G_2 \subset \dots \subset G_{\max}$, имеет место

$$O(\bigcup_i G_i, \inf(G_1)) = O(G_{\max}, O(G_{\max-1}, \dots, \inf(G_1) \dots)) \quad (2)$$

Мультишкала, представляемая формулой, существует благодаря тому, что все подгруппы из последовательности поиска принадлежат одному и тому же экземпляру SO_N . При анализе симметрий для альтернативных конфигураций необходимо использовать еще один критерий, который позволял бы сравнивать степени непрерывности или однородности заполнения орбит симметрий, соответствующих несопадающим вариантам конфигурации кластеров. При наличии данного критерия мультишкала (2) может быть распространена на все многообразие \mathcal{S} .

Работа выполнена при поддержке РФФИ (проекты №03-01-00580, 04-07-00333, 05-01-00332).

Литература

1. Vinogradov A., Voracek J., Zhuravlev Yu., Stochastic Filtering of Approximate Symmetries in Thick Packs of Clusters // "Pattern Recognition and Image Analysis", 2005 (to appear).

Приближенный алгоритм для апостериорного обнаружения в числовой последовательности квазипериодически повторяющегося фрагмента при заданном числе повторов

Э.Х. Гимади, А.В. Кельманов, М.А. Кельманова, С.А. Хамидуллин
(Новосибирск)

Рассматривается апостериорный (off-line) подход к решению задачи обнаружения в числовой последовательности неизвестного квазипериодически повторяющегося фрагмента. Анализируется случай, когда: 1) число повторов известно, 2) номер члена последовательности, соответствующий началу фрагмента, – детерминированная (не случайная) величина, 3) для наблюдения доступна последовательность, искаженная аддитивной гауссовской некоррелированной помехой.

На сегодняшний день для решения этой задачи не известны какие-либо полиномиальные алгоритмы апостериорного типа с оценками их точности. Существующие апостериорные полиномиальные алгоритмы ориентированы на случай, когда искомый фрагмент принадлежит заданному алфавиту [1,2].

Одна из возможных содержательных интерпретаций задачи состоит в

следующем. Источник сообщений передает повторяющийся импульс неизвестной формы. Через канал передачи на приемник поступает и накапливается последовательность импульсов, искаженная аддитивным шумом. Моменты времени появления импульсов в принятой (наблюдаемой) зашумленной последовательности неизвестны. Однако известно общее число переданных импульсов. Требуется обнаружить импульсы в принятой последовательности. Эта содержательная задача типична для таких приложений как электронная разведка, радиолокация, телекоммуникация, геофизика, обработка речевых сигналов, медицинская и техническая диагностика и др. [3].

Формально, пусть компоненты вектора $X \in \mathfrak{R}^N$ образованы по правилу: $x_n = \sum_{m=1}^M u_{n-n_m}$, $n = \overline{0, N-1}$, где $u_n = 0$, при $n < 0$ и $n > q-1$ (q – натуральное число). Положим $U = (u_0, \dots, u_{q-1})$ и назовем U эталонным вектором. В соответствии с указанным правилом фрагмент $(x_{n_m}, \dots, x_{n_m+q-1})$, $m = \overline{1, M}$, последовательности компонент вектора X совпадает эталонным вектором U .

Положим $\eta = (n_1, \dots, n_M)$ и допустим, что $\eta \in \Omega_M = \{(n_1, \dots, n_M) : 0 \leq n_1 \leq T_{\max} - q; q \leq T_{\min} \leq n_m - n_{m-1} \leq T_{\max}, m = \overline{2, M}; 0 \leq N - T_{\max} \leq n_M \leq N - q\}$, $M \in [M_{\min}, M_{\max}]$, где $M_{\min} = \lfloor (N + q - 1) / T_{\max} \rfloor$ и $M_{\max} = \lfloor (N - q) / T_{\min} \rfloor + 1$, см. [1].

В определении множества Ω_M пара ограничений на n_1 и n_M – крайние условия, а третье ограничение – условие квазипериодичности повторов. Элементы набора η интерпретируются как квазипериодические моменты времени начала импульсов в последовательности. Компоненты вектора $X = X(\eta, U)$ образуют квазипериодическую последовательность, порожденную эталонным вектором U .

Пусть наблюдаемый случайный вектор $Y = X(\eta, U) + E$, где $E \in \Phi_{0, \sigma^2 I}$. Задача обнаружения состоит в том, чтобы по вектору Y найти максимально правдоподобный набор η . Параметры задачи N , T_{\max} , T_{\min} , q и σ считаются известными, а вектор U – неизвестным.

Установлено, что решаемая задача состоит в проверке совокупности сложных гипотез о среднем значении X случайного гауссовского вектора Y ; специфика задачи заключается в том, что мощность этой совокупности

растет экспоненциально с увеличением числа членов последовательности N и числа повторов M .

Показано, что отыскание максимально правдоподобной гипотезы сводится к максимизации вспомогательной целевой функции, т.е.

$$F(\eta) = \sum_{i=1}^M \sum_{j=1}^M (Y_{n_i}, Y_{n_j}) \rightarrow \max_{\Omega_M},$$

где $Y'_n = (y_n, \dots, y_{n+q-1})$, $n = \overline{0, N-q}$, (\cdot, \cdot) – скалярное произведение.

Доказано, что задача максимизации этой функции в общем случае NP-трудна; к частному случаю этой задачи сведена известная NP-полная задача о клике [4], содержащей заданное число вершин графа. Задача полиномиально разрешима, когда $T_{\min} = T_{\max}$ (при любом допустимом M) и когда $M \leq 2$ (при любых допустимых T_{\min} и T_{\max}).

Предложен приближенный алгоритм решения этой задачи. Алгоритм включает два этапа. На первом этапе находится начальное приближение – решается задача

$$G(n_1, \dots, n_M) = \sum_{i=1}^M \|Y_{n_i}\|^2 \rightarrow \max_{\Omega_M}.$$

Для максимизации этой функции получены рекуррентные формулы динамического программирования. Поиск начального приближения в указанном виде мотивирован тем, что имеет место оценка

$$F = M \sum_{i=1}^M \|Y_{n_i}\|^2 - \frac{1}{2} \sum_{i=1}^M \sum_{j=1}^M \|Y_{n_i} - Y_{n_j}\|^2 \leq M \sum_{i=1}^M \|Y_{n_i}\|^2 = MG.$$

Трудоёмкость поиска начального приближения есть величина $\sim M(T_{\max} - T_{\min} + 1)(N - q + 1)$, а затраты по памяти оцениваются величиной $\sim MN$.

На втором этапе аргументы, доставляющие максимум целевой функции G , используются для улучшения приближения методом покоординатного подъема. Затраты по времени на одну итерацию не превосходят затрат на поиск начального приближения, а суммарные затраты по памяти есть величина $\sim M^2$.

Работоспособность алгоритма проверена в многочисленных

экспериментах при различных значениях параметров алгоритма и уровнях помехи. В большинстве случаев локальный экстремум находился за несколько итераций, причем число итераций не превосходило числа M . В целом, данные численного моделирования демонстрируют эффективность и помехоустойчивость алгоритма, приемлемую с точки зрения приложений.

Работа выполнена в рамках проекта № 03-01-00036, поддержанного РФФИ.

Литература

1. Кельманов А.В., Хамидуллин С.А. Апостериорное обнаружение заданного числа одинаковых подпоследовательностей в квазипериодической последовательности // Журн. вычисл. математики и математической физики. 2001. Т. 41, № 5. С. 807-820.
2. Кельманов А.В., Хамидуллин С.А. Апостериорное совместное обнаружение и различение заданного числа подпоследовательностей в квазипериодической последовательности // Сиб. журн. индустриальной математики. 1999. Т.2, № 2 (4). С. 106-119.
3. Kel'manov A.V., Jeon B. A Posteriori Joint Detection and Discrimination of Pulses in a Quasiperiodic Pulse Train // IEEE Transactions on Signal Processing, Vol. 52, No. 3, March 2004, pp. 1-12.
4. Gaery M.R., Johnson D.S. Computers and Intractability: A Guide to the Theory of NP-Completeness, Freeman, San Francisco, CA, 1979.

Восстановление 3D поверхности лиц на базе исходных 2D изображений

А.Б. Глаз, А.А. Тимухин
(Рига)

Введение

В задачах распознавания изображений часто приходится строить решающее правило на недостаточных обучающих выборках. Такой случай, например, имеет место при распознавании человеческих лиц, когда обучающая выборка предоставлена несколькими изображениями (обычно профиль и фас). В этом случае для увеличения объема обучающей выборки и, соответственно, повышения эффективности классификации может быть использовано восстановление 3D поверхности лица. Первые результаты в этом направлении были опубликованы в [1].

Одна из задач, которые человек решает достаточно эффективно – определение формы 3D объектов по их 2D изображениям. Представление о форме формируется при учёте множества факторов: интенсивности отражённого света и его цвета, симметрии контуров, искажения текстуры и др.[2], при этом, существенную роль может играть контекст, в рамках

которого рассматривается изображение. В данной работе рассматривается возможность использования интенсивности отражённого света для получения информации о форме и цвета для определения материалов. Восстановленная поверхность даёт возможность эффективно создавать виртуальные изображения, то есть увеличивать объём обучающей выборки, что позволяет повысить надёжность дальнейшей классификации объектов.

Модели освещённости

Примем, что имеется один точечный источник света расположенный далеко от объекта. Рассмотрим диффузионное и зеркальное отражение света[2,3]. Цвет на изображении в точке с координатами (x,y) в этом случае будет

$$C(x, y) = C_0 + C_D \mathbf{L} \cdot \mathbf{N} + C_S [(2(\mathbf{L} \cdot \mathbf{N}) \cdot \mathbf{N} - \mathbf{L}) \cdot \mathbf{V}]^n$$

или равносильно

$$C(x, y) = C_0 + C_D \cos(\alpha) + C_S \cos(\beta)^n$$

где \mathbf{L} – направление на источник света, \mathbf{N} – нормаль к поверхности, \mathbf{V} – направление на камеру, n – параметр, регулирующий ширину отражённого лепестка, C_0 – цвет наименее освещённого элемента поверхности, C_D – диффузионная компонента цвета, C_S – зеркальная компонента цвета, α – угол между нормалью и направлением на источник, β – угол между направлением отражённого луча и направлением на камеру. Цвет представляет трехкомпонентный вектор $\mathbf{C}=(c_R, c_G, c_B)$ в системе RGB. Векторы $\mathbf{L}, \mathbf{N}, \mathbf{V}$ имеют единичную длину.

Все дальнейшие построения используют эту простую модель освещения, которая задаёт соответствие между цветом и формой поверхности. В уравнении форма поверхности задана с помощью нормалей, то есть неявно, соответственно, поверхность задана с точностью до аддитивной константы.

В этом случае для построения поверхности требуется информация о расположении объектов сцены (распределение материалов на поверхности, расположение камеры и источника света).

Алгоритм построения поверхности

На первом этапе создаётся минимальная решётка с опорными точками. Решетка преобразуется по методу Лупа [4] в гладкую поверхность. Начальная решётка не симметрична (составляет только половину лица), поэтому конечная поверхность симметрично дополнена.

Параметры освещения и видовые параметры подбираются вручную. Для этого поверхность отображается вместе с исходным изображением и производится размещение поверхности и источника света. Далее с

исходного изображения считываются характеристики материала. Для этого выделяются пиксели в центре C_2 , на границе бликов C_1 и в области наименьшего освещения C_0 . Цветовые компоненты C_D , C_S определяются следующим образом:

$$C_S = C_2 - C_0 + C_D; \quad C_D = C_1 - C_0$$

Затем опорные точки сдвигаются так, чтобы обеспечить наилучшее совмещение контуров с исходного изображения и полученного для поверхности. Данный шаг осуществляется в два этапа. На первом – все точки сдвигаются в соответствии с модификацией контрольного объема, заданного шестью точками. Затем соответствие контуров и отражений с поверхности и изображения улучшается за счёт смещения отдельных опорных точек.

Экспериментальные результаты

На рисунке 1 приведены исходные изображения (анфас и профиль).



Рис. 1. Исходные изображения.

На рис 2а показана 3D поверхность, восстановленная только по изображению 1.а, на рис 2б – изображение (профиль), полученное трансформацией поверхности 2а.




Рис. 2. Восстановленная поверхность по изображению в анфас.

На рис 3а показана 3D поверхность, восстановленная только по изображению 1.б, на рис 3б – изображение (анфас), полученное трансформацией поверхности 3а.




Рис. 3. Восстановленная поверхность по изображению в профиль.

Нетрудно убедиться, что изображения 2б и 3а или изображения 2а и 3б близки. Степень близости увеличивается с увеличением количества изображений, используемых для построения 3D поверхности. Это позволяет генерировать новые изображения путём трансформации построенной 3D поверхности.

Литература

1. Глаз А., Крейцс И. Применение трёхмерных преобразований в распознавании лиц. //Computer science. "RTU" Riga 2002.
2. Дэвид Форсайт, Жан Понс. Компьютерное зрение. //Издательский дом «Вильямс». 2003.
3. James Foley, Andries van Dam, Steven Feiner, John Hughes. Computer Graphics. //Principles and practice. Second edition in C
4. Столниц Э., ДуРоуз Т., Салезин Д. Вейвлеты в компьютерной графике. Теория и приложения. //РХД Москва Ижевск 2002.

О разрешимости и регулярности задач распознавания со специальной структурой F-расширений моделей алгоритмических операторов

Ю.И. Горелов

(Тула)

Задачи восстановления зависимостей и прогноза, решаемые путем применения элементов теории распознавания образов [1], часто сводятся к задачам распознавания со специальной структурой F-расширений моделей алгоритмических операторов. В настоящем докладе приводятся полученные автором критерии разрешимости и регулярности данного класса задач распознавания.

Пусть пространства начальных и финальных информаций I_i и I_f имеют вид:

$$I_i = Z \times I'_i; \quad I_f = \{0,1\};$$

заданы локальные ограничения I_s^l в виде q -последовательностей $\{x_i\}_1^q$ и $\{y_i\}_1^q$ элементов l_i и l_f , соответственно, и требования

$$A(\{x_i\}_1^q) = \{y_i\}_1^q;$$

и универсальные ограничения I_s^u , характеризующиеся требованием

$$A(\{x_i\}_1^q) = \{A(x_i)\}_1^q;$$

то есть алгоритм A , решающий задачу, есть q -я степень некоторого отображения (все объекты однородны и независимы). Отметим, что таким универсальным ограничениям соответствует функциональная категория Φ_0 [2].

Алгоритм решения поставленной выше задачи будем искать в рамках F -расширений [2] при следующих ограничениях на M^0 , M^1 и F :

$$\begin{aligned} M^0 &= \tilde{M}^0 \cup \{B_0\}; M^1 = \{C_0\}; \\ F &= \{F(B_0, B_1, \dots, B_p) = B_0 + \tilde{F}(B_1, \dots, B_p) \mid \\ &\tilde{F} \in \tilde{F}; (B_1, \dots, B_p) \in (\tilde{M}^0)^p; B_0 \in M^0\}, \end{aligned}$$

где B_0 - проектор из пространства l_i в Z ; C_0 - унарное решающее правило вида

$$C_0(\gamma) = \begin{cases} 1; & \gamma \geq 0; \\ 0; & \gamma < 0; \end{cases} \quad \forall \gamma \in l_e.$$

Отметим, что B_0 и $(+)$ являются морфизмами категории Φ_0 , а C_0 - ввиду своей сюръективности, корректным решающим правилом [2]. Нетрудно заметить, что пространство возможных оценок [3] $l_e = Z$ и должно быть наделено структурой алгебраической системы с сигнатурой $(T, P) = (+, \tilde{F}, \geq)$, при этом для любого $x = (z, \tilde{x}) \in l_i$ алгоритм A имеет вид

$$A(x) = C(z + \tilde{F}(B_1(x), \dots, B_p(x))).$$

Алгоритму A может быть поставлена в соответствие разделяющая

функция

$$z = -\tilde{F}(B_1(x), \dots, B_p(x)) = \tilde{F}'(B_1(x), \dots, B_p(x)),$$

где 0 - единица группы $\langle Z, + \rangle$; а $\tilde{F}'(B_1(x), \dots, B_p(x))$ - обратный элемент группы $\langle Z, + \rangle$ к $\tilde{F}(B_1(x), \dots, B_p(x))$.

Лемма 1. Для того, чтобы алгоритм A безошибочно распознавал любые $x \in I_i$ достаточно выполнения условия

$$\begin{aligned} \forall x(((y_x = 1) \rightarrow (z_x \geq \tilde{F}'(B_1(x), \dots, B_p(x)))) \vee \\ (y_x = 0) \rightarrow (z_x < \tilde{F}'(B_1(x), \dots, B_p(x))))); \end{aligned}$$

где $x = (z_x, \tilde{x})$, а y_x - соответствующий x элемент пространства I_f .

Предположим без ограничения общности, что для первых q_0 элементов $\{x_i\}_1^q$ справедливо $y_i = 1, i \in \{1, \dots, q_0\}$, а для остальных $(q - q_0)$ - $y_i = 0, i \in \{q_0 + 1, \dots, q\}$.

Лемма 2. Для корректности алгоритма A достаточно выполнения условий

$$\begin{aligned} \tilde{F}'(B_1(x_i), \dots, B_p(x_i)) = z_i - \delta_i = z'_i; i \in (1, \dots, q_0); \\ \tilde{F}'(B_1(x_i), \dots, B_p(x_i)) = z_i + \delta_i = z'_i; i \in (q_0 + 1, \dots, q); \end{aligned}$$

где $\{\delta_i\}_1^q$ - положительные элементы алгебраической системы I_e .

Тогда решение задачи распознавания сводится к выбору такой корректирующей операции $\tilde{F}' \in F$, таких $\{\delta_i\}_1^q$ и таких алгоритмических операторов B_1, \dots, B_p , чтобы выполнялись условия леммы 2. Отметим, что натуральное число p не фиксировано и находится в процессе синтеза корректного алгоритма.

Обозначим через $\bar{a}_i = (B_1(x_i), \dots, B_p(x_i)) \in I_e^p$. Справедлив следующий критерий разрешимости и регулярности рассматриваемой задачи распознавания

Теорема 1. Для разрешимости задачи распознавания достаточно, чтобы

$$\forall_{\substack{i_1 \neq i_2 \\ (i_1, i_2) \in \{1, \dots, q\}^2}} (i_1, i_2) (\bar{a}_{i_1} = \bar{a}_{i_2}) \rightarrow (z'_{i_1} = z'_{i_2});$$

для регулярности задачи достаточно, чтобы

$$\forall_{\substack{i_1 \neq i_2 \\ (i_1, i_2) \in \{1, \dots, q\}^2}} (i_1, i_2) (\bar{a}_{i_1} \neq \bar{a}_{i_2}).$$

Работа выполнена при финансовой поддержке РФФИ, грант № 03-01-00810.

Литература

1. 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.
2. Рудаков К.В. Об алгебраической теории универсальных и локальных ограничений для задач классификации // Распознавание, классификация, прогноз. М.: Наука, 1989. С. 176-201.
3. Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики. -М.: Наука, 1978. - Вып.33. - С. 5-68.

Определение областей компетентности алгоритмов синтеза управляющих систем

М.В. Гранкин, С.И. Гуров
(Москва)

Введение. Постановка задачи

Электронные управляющие системы в различных областях деятельности, как правило, реализуются на основе больших интегральных схем. На сегодняшний день существуют различные алгоритмы решения задачи логического синтеза, базирующиеся на разных системах эвристик. При этом различные алгоритмы демонстрируют различную эффективность на различных типах схем. Кроме того, данная эффективность может определяться исходя из ряда критериев (площадь, занимаемая схемой на кристалле, общая задержка по критическому пути, потребляемая мощность и т.д.). Сегодня на повестке дня стоит разработка алгоритмов логического синтеза нового поколения. Такие алгоритмы могли бы осуществлять синтез отдельных частей большой ИС, исходя из дифференцированных критериев, применяя различные классы алгоритмов. Иначе говоря, синтезирующая программа должна быть «чувствительна» к специфическим особенностям поведенческого описания тех или иных

участков схемы с учётом их взаимосвязей с другими участками и общего задаваемого критерия эффективности.

Первым этапом к построению таких программ может служить решение задачи определения областей компетентности уже существующих алгоритмов логического синтеза.

Областью компетентности алгоритма оптимизации называется подмножество в пространстве характеристик входного описания, для которых данный алгоритм оптимален по выбранному критерию.

Задачу определения областей компетентности естественно решать методами распознавания образов. Для её решения необходимо сформировать пространство признаков. Рассматриваемая задача характеризуется тем, что здесь явно не выполняется гипотеза компактности. Формирование признакового пространства производилось на основе метода предложенного М.М. Бонгардом [1.1]. Метод заключается в поиске правильного ответа методом угадывания/подбора: (1) выбор некоторого набора исходных признаков (это *первичные признаки*, они, как правило, не дают возможности провести эффективное распознавание непосредственно); (2) генерация *вторичных признаков*; (3) отбор вторичных признаков с максимальной информативностью.

Критерием оптимальности алгоритма принимается размер конечной схемы (возможны и другие критерии: общая задержка, энергопотребление, комбинированные критерии и т.д.).

Построение классификатора

Построение классификатора, решающего поставленную задачу проводилось в рамках системы SIS [1.2]. В качестве прецедентов были взяты описания схем трёх типов: (1) математические функции (примеры функций, идущие в комплекте с системой SIS), (2) промышленные схемы (также из SIS) и (3) схемы сгенерированные случайным образом. Описания логики брались в виде ПЛМ.

В системе SIS имеется 19 алгоритмов, вызываемых вызываемых скриптами (приведены ниже в табл. 1). При функционировании SIS после её минимизации производится перевод описания из некоторого внутреннего представления в представление, достаточное для запуска схемы в производство (*mapping*). В частности, на этом этапе определяется площадь синтезированной схемы (в условных единицах). Для каждого описания схемы этот процесс повторялся 19 раз – по количеству алгоритмов минимизации.

Было эмпирически выбрано 10 первичных признаков: количество входов, выходов и интервалов задания частично заданной булевой функции, средние числа «0», «1» и «-» (неопределённые состояния) в записи интервалов, задающих входы, входы функции, дисперсии этих величин и т.п.

Построение вторичных признаков проводилось комбинированием из первичных с помощью элементарных арифметических операций (при этом использовался рекурсивный метод с проверкой на повторения).

Селекция вторичных признаков проводилась методом скользящего анализа. Выборка разбивалась на две группы: на одной группе происходило обучение, на другой – тестирование результатов. В качестве критерия успешности был взят выбор признака, который улучшает угадывание одного из 4 наилучших результатов.

Результаты. Заключение

Описанный алгоритм был запрограммирован в среде ОС Debian (Unix) на ПК. Некоторые результаты тестовых экспериментов приведены в таблице 1.

Таблица 1. Распределение описаний схем по алгоритмам минимизации

№	Название	Количество функций, для которых скрипт входит в 4 наилучших
1	script.algebraic	41
2	script.boolean	32
3	script.delay	17
4	script.espresso	2
5	script.fsal	4
6	script.fsalg	2
7	script.fsals	0
8	script.fsalt	0
9	script.fsaltg	0
10	script.fsalts	0
11	script.fsar	1
12	script.fsat	0
13	script.jordi	13
14	script.mcnc	64
15	script.mfs	68
16	script.mfsr	43
17	script.msu	64
18	script.oct	62
19	script.rugged	67

Всего было обработано 120 входных описаний схем, при этом разработанная программа осуществила правильный выбор в 101 случаях.

Одним из возможных улучшений системы является использование более сложного класса функций и совмещение блоков генерации

вторичных признаков и селекции признаков (другими словами после построения нового признака происходит оценка его полезности). Таким способом можно достичь полного отсутствия ошибок на процессе обучения. Однако, он требует значительных ресурсов системы: как по быстрдействию, так и по памяти для хранения полного набора вторичных признаков.

В данной работе продемонстрирован подход к задаче распознавания, когда пространство признаков *a priori* не определено и не ясно, как его определять. Не смотря на то, что задача формирования признакового пространства переборная, подход демонстрирует удовлетворительные результаты даже на персональном компьютере.

Работа выполнена при финансовой поддержке РФФИ (код проекта 04-01-00161) и ЗАО «Интел А/О».

Литература

1. Бонгард М.М. Проблема узнавания. - М.: Наука, 1967.
2. SIS. A System for Sequential Circuit Synthesis / Dep. of Electrical Engineering and Comp. Science Univ. of California, - Berkeley. Electronic Res. Lab, Memorandum No. UCB/ERL M92/41.

Оценки числа монотонных булевых функций с данным числом нижних единиц

С.И. Гуров
(Москва)

Введение. Основные обозначения

Статья [1.1] завершила исследования Ж. Анселя, Э.Н. Гильберта, В.К. Коробкова Д. Клейтмана и др. по изучению классов M^n монотонных булевых функций (МБФ) от n переменных. В ней приведены асимптотическая оценка мощности $|M^n| = \psi(n)$ и указаны номера слоёв булева единичного куба B^n , содержащие нижние единицы почти всех функций из M^n . Следующим шагом логично было бы перейти к изучению структуры МБФ по отношению к тому или иному параметру. Характерным параметром МБФ является число l её нижних единиц. При исследовании дискретных задач распознавания образов возникает задача о покрытии, тесно связанная с МБФ. Тогда n есть число признаков, отделяющие тесты описываются единичными множествами МБФ, а их верхние нули задают тупиковые тесты. При больших n и малом числе прецедентов имеет место случай малых по сравнению с n значений l (очевидно, в силу симметрии вместо верхних нулей можно рассматривать нижние единицы МБФ, что несколько удобнее).

Ниже будут даны оценки функции $\psi(n)$ – мощности множества M_l^n МБФ от n (не обязательно существенных) переменных с l нижними единицами. При этом предполагается, что $l \leq n$ или $l = \text{const}$ при $n \rightarrow \infty$. Далее E_n обозначает $C_n^{\lfloor n/2 \rfloor}$ – мощность среднего слоя B^n .

Случай $l = 0, 1, 2$. От n к $n+1$

Понятно, что $\psi_0(n) = 1$ (константа 0) и $\psi_0(n) = 2^n$ (случай нулевой вершины соответствует константе 1). Далее, мощность множества вершин B^n , сравнимых с данной вершиной, находящейся в слое k равна $2^k + 2^{n-k} - 1$. Поэтому

$$\psi_2(n) = \frac{1}{2} \sum_{k=0}^n \left(C_n^k \left(2^n - \left(2^k + 2^{n-k} - 1 \right) \right) \right) = \frac{2^{2n} - 2 \cdot 3^n + 2^n}{2}.$$

Пусть определено $\psi_l(n)$. Каждая функция из M_l^n описывается набором своих нижних единиц или бинарной $l \times n$ таблицей, где строки соответствуют вершинам B^n (нижним единицам). Приписав к такой таблице ещё один произвольный бинарный столбец, получим описание некоторой МБФ от $n+1$ переменной. Таким образом,

$$2^l \psi_l(n) \leq \psi_l(n+1).$$

Легко показывается, что приписывание такого столбца в качестве i -го, $i = 1, \dots, n+1$ указанным таблицам даст (возможно повторяющиеся) описания всех функций из M_l^{n+1} . Отсюда

$$\psi_l(n+1) \leq 2^l (n+1) \psi_l(n).$$

Следовательно, справедлива оценка

$$2^{l(n-n_0)} \psi_l(n_0) \leq \psi_l(n) \leq 2^{l(n-n_0)} (n)_{n-n_0} \psi_l(n_0),$$

где $n_0 = k$ удовлетворяет условию « l – максимальное целое, не превосходящее $C_n^{\lfloor n/2 \rfloor}$ » ($(n)_r = n \cdot (n-1) \cdot \dots \cdot (n-r+1)$).

Нижняя оценка $\psi_l(n)$. От l к $l+1$

Справедлива тривиальная оценка

$$2[Od(n)] \cdot C_{E_n}^l \leq \psi_l(n),$$

когда все нижние единицы МБФ располагаются в среднем (средних) слоях

B^n ($2[Od(n)]$ означает, что коэффициент 2 берётся при нечётных n). При $l \leq n$, считая, что все, кроме одной вершины МБФ находятся в 1-м слое с определением мощности сравнимых с ними вершин $(2^n - 2^{n-l+1})$, получаем оценку

$$2[Od(n)] \cdot \left((2^{n-l+1} - n + l - 2) \cdot C_{E_n}^{l-1} + C_{E_n}^l \right) \leq \psi_l(n), \quad l \leq n,$$

увеличивающую предыдущую асимптотически в $1 + l\sqrt{2\pi n}/2^l$ раз. Для дальнейших асимптотических оценок получена и несколько более точная (но более громоздкая) нижняя оценка $\psi_l(n)$.

Для получения верхней рекуррентной оценки полагаем расположение l нижних единиц в среднем слое B^n и применяем формулу из [2] для нижней оценки сравнимых с ними вершин B^n , которая в нашем случае даёт величину $C \cdot 2^{n/2} (1 - 2^{-l})^{-l}$, где $C = 6/\sqrt{2}$ и $C = 4$ при n нечётном и чётном соответственно. В результате получаем оценку

$$\psi_{l+1}(n) \leq \psi_l(n) \cdot \left(2^n - C \cdot 2^{n/2} \cdot \left(1 - \frac{1}{2^l} \right) + l \right).$$

Из приведённых формул можно получить двойное неравенство аналогичное последнему в предыдущем разделе.

Заключение

В данной работе представлены самые предварительные оценки функции $\psi_l(n)$. Для приведённых формул может быть найдены асимптотики при $n \rightarrow \infty$ и различных вариантах зависимостей l от n . В следующей работе будет введена комбинаторно-вероятностная модель МБФ, с помощью которой, в частности, будет показано, что $\psi_l(n) \sim 2^{\ln l}/l!$ при $n \rightarrow \infty$.

Автор глубоко признателен Ю.И. Журавлёву за неизменную поддержку и А.А. Сапоженко за ценные консультации.

Работа выполнена при финансовой поддержке РФФИ (код проекта 04-01-00161).

Литература

1. Коршунов А.Д. О числе монотонных булевых функций // Проблемы кибернетики. Вып 38, 1981. - С. 5-108.
2. Гулов С.И. Логические алгоритмы распознавания, основанные на разложении Гильберта // Журнал вычислительной математики и математической физики, 2003, том 43, № 8. - С. 1243-1248.

Обучение распознаванию с учетом априорной упорядоченности объектов

С.Д. Двоенко
(Тула)

Введение

Традиционная постановка задачи распознавания образов предполагает, что объекты обучающей выборки расположены в некотором признаковом пространстве и объективно принадлежат к одному из конечного числа классов. Основное предположение, основанное на «гипотезе компактности» и позволяющее надеяться на успешное решение задачи распознавания, обычно состоит в предположении о разделимости классов, представленных объектами обучающей выборки. Рассмотрим случай двух классов.

Разделимость классов означает, что, по меньшей мере, выпуклые оболочки множеств, образованных объектами обучающей выборки, принадлежащими разным классам, не пересекаются. Такое предположение позволяет представить результат обучения в виде разделяющей гиперплоскости. Если выпуклые оболочки разделяемых множеств объектов обучающей выборки не соприкасаются, то, очевидно, что в «зазоре» между ними можно построить более одной разделяющей гиперплоскости. В отсутствие иной априорной информации обычно выбирают гиперплоскость, «наиболее удаленную от выпуклых оболочек разделяемых множеств». Такое оптимальное решающее правило обеспечивает наименьшее число ошибок распознавания на множестве объектов, не участвующих в обучении [1, 2].

Учет априорной упорядоченности объектов

Часто объекты, предъявленные для распознавания, образуют массив данных, который имеет смысл рассматривать целиком как массив «взаимосвязанных» данных [3]. Учет априорной «упорядоченности» взаимосвязанных объектов позволяет построить эффективные процедуры собственно распознавания, основанные, например, на аппарате скрытых марковских цепей [4], позволяя на этапе обучения все же воспользоваться хорошо известными классическими алгоритмами, которые опираются на предположение о независимом предъявлении объектов обучающей выборки.

В анализе данных широко применяется подход к конструированию алгоритмов распознавания и классификации с учетом содержательной информации различного вида – контекстное распознавание образов [5].

Учет априорной «упорядоченности» взаимосвязанных объектов позволяет строить алгоритмы обучения с новыми свойствами. Пусть объекты некоторого класса характеризуются величиной, значение которой

определяет степень выраженности дополнительного определенного свойства у объектов данного класса. Тем не менее, мы не можем использовать эту величину как еще один признак, т.к. объекты другого класса в общем случае могут и не обладать данным свойством. Было бы естественным потребовать для искомой разделяющей гиперплоскости, чтобы проекции объектов данного класса на ее направляющий вектор (перпендикулярный к самой гиперплоскости) оказались упорядоченными в соответствии со степенью выраженности указанного дополнительного свойства у них.

Очевидно, что в многомерном пространстве всегда можно найти направление, на оси которого будет получено требуемое упорядочение объектов по степени выраженности у них такого дополнительного свойства. Но соответствующая гиперплоскость может оказаться неоптимальной и даже вообще не быть разделяющей.

В итоге, необходимо построить такую разделяющую гиперплоскость, у которой на оси ее направляющего вектора упорядочение объектов обучающей выборки, обладающих дополнительным свойством, наименьшим образом отличалось бы от заданного, а сама гиперплоскость являлась наиболее удаленной от выпуклых оболочек разделяемых множеств среди всех гиперплоскостей, дающих такое упорядочение.


Очевидно, что такая постановка задачи обучения может быть расширена на случаи шкал различных типов, пересекающихся классов, а также сформулирована в рамках концепции «беспризнакового» распознавания образов [6].

Пример задачи распознавания

Ранее была построена пространственная модель расположения зон коллекторов в кристаллическом фундаменте месторождения Бомбей Хай на западном прибрежном шельфе Индии в Аравийском море [7]. Данными учителя служили 19 скважин, вскрывших породы фундамента. Эксперты указали зоны коллекторов и неколлекторов в каждой из скважин по данным каротажа, гидродинамических испытаний и измерения притока флюидов (нефти, газа, воды). Расположение скважин на глубине 500 м под верхней границей фундамента показано на рисунке. Заштрихованные области соответствуют карте областей коллекторов на той же глубине, найденных в результате решения задачи распознавания на массиве взаимосвязанных объектов [3, 4]. Зоны коллекторов покрывают все области, ранее рекомендованные экспертами для бурения.

На тех же данных учителя была построена карта областей коллекторов с учетом численных значений притока флюидов испытательных скважин. На глубине 500 м приток неколлекторов считался нулевым, а приток коллекторов по результатам испытаний находился в пределах от 200 до 2623 б/сут. Таким образом, все скважины с притоком флюидов оказались

естественным образом упорядоченными по его величине. Учет априорной упорядоченности коллекторов по притоку на этапе обучения позволил указать зоны коллекторов с предполагаемым высоким притоком. Расположение этих зон оказалось согласованным с ранее построенной картой.



Литература

1. Козинец Б.Н. Рекуррентный алгоритм разделения выпуклых оболочек двух множеств // Алгоритмы обучения распознаванию образов / Под. ред. В.Н. Вапника. М.: Сов. Радио, 1973. С. 43-50.
2. Vapnik V.N. Statistical Learning Theory. J. Wiley & Sons, 1998.
3. Двоенко С.Д. Распознавание образов в массивах взаимосвязанных данных // Докл. ММРО-10, 2001. С. 37-40.
4. Двоенко С.Д., Копылов А.В., Моттль В.В. Задача распознавания образов в массивах взаимосвязанных объектов. Постановка задачи и основные предположения // Автоматика и телемеханика, №1, 2004. С. 143-158.
5. Toussaint G.T. The Use of Context in Pattern Recognition // Pattern Recognition, vol. 10, 1977. P. 189-204.

6. Моттль В.В. Метрические пространства объектов беспризнакового распознавания образов, допускающие введение линейных операций и скалярного произведения // Тр. конф. РОАИ-6-2002, Т.2. С. 384-388.
7. Mottl V., Dvoenko S., Levyant V., Muchnik I. Pattern recognition in spatial data: A new method of seismic explorations for oil and gas in crystalline basement rocks // Proc. of ICPR'2000, vol.3. P. 210-213.

Достижения и перспективы развития обобщенного спектрально-аналитического метода в решении сложных информационных задач

Ф.Ф. Дедус

(Пушино)

Прошло около 10 лет с того времени, когда был сформулирован спектрально-аналитический метод (ОСАМ) обработки информационных сигналов [1]. Основное его отличие от других методов обработки в том, что это, прежде всего, спектральный метод. Он основан на широком применении систем алгебраических классических ортогональных полиномов и функций непрерывного и дискретного аргументов. Это также комбинированный численно-аналитический метод. В нем, с одной стороны, применяются числовые расчеты на ЭВМ для разложения в ряд поступающих информационных данных по выбранному ортогональному базису с требуемой точностью, а с другой – полученное аналитическое описание сигналов в виде отрезков ортогональных рядов используется в аналитических преобразованиях и выводах для получения необходимых оценок и характеристик. Этот подход оказался настолько рациональным и гибким, что его дальнейшее развитие мы рассматриваем как важную и актуальную задачу.

Широкое применение ортогональных базисов из числа классических продиктовано следующими обстоятельствами. В большинстве задач при аналитическом описании информационных данных для повышения эффективности их обработки были сформулированы условия – путем использования разработанных адаптивных процедур при аналитическом описании сигналов необходимо обеспечивать заданную точность при соблюдении условия минимально возможного числа членов N в отрезке ортогонального ряда, то есть $N=N_{\min}$. В ряде специальных случаев, наоборот, требуется получение с высокой точностью аналитического описания сложных сигналов отрезками сверхдлинных ортогональных рядов от нескольких сотен до нескольких тысяч членов разложения.

Далее неизбежно возник вопрос, как эффективно обрабатывать столь различные по глубине разложения аналитические описания информационных сигналов. В любом отрезке ортогонального ряда полезная информация содержится только в коэффициентах разложения.

Поэтому было решено разработать такие алгоритмы обработки, которые позволили бы извлекать полезную информацию непосредственно из коэффициентов разложения. Известно, что для полных систем аналитических ортогональных функций из числа классических справедливо равенство Ляпунова-Стеклова, доказанное в 1896 году:

$$\int_a^b f^2(t) \rho(t) dt = \sum_{n=0}^{\infty} A_n^2$$

где $f(t)$ – сигнал, описываемый отрезком ортогонального ряда; A_n – коэффициенты разложения сигнала $f(t)$ по принятой ортонормированной системе $\{\varphi_n(t)\}$.

Указанное равенство свидетельствует о том, что система ортонормированного базиса $\{\varphi_n(t)\}$ является полной (или замкнутой).

Из этого следует, что разложение в ряд по функциям $\{\varphi_n(t)\}$ является жестким, то есть члены ряда линейно независимы между собой. При необходимости повышения точности описания следует вычислять новые члены ортогонального ряда; ранее вычисленные коэффициенты разложения остаются неизменными.

В предлагаемом докладе рассмотрены наиболее важные направления эффективного решения некоторых прикладных задач на основе ОСАМ. К таким направлениям относятся, прежде всего, задача параметрической идентификации сложных систем и их технической диагностики, задачи распознавания образов, анализа изображений и сцен, а также комплекс задач, связанных с обработкой информационных данных, получаемых в различных научных и технических приложениях.

Прежде всего, сосредоточим внимание на последовательности разработки алгоритмов распознавания образов и сцен в пространстве коэффициентов разложения. Получаемые при этом признаковые пространства позволяют в процессе исследований выделять оптимальные (наиболее информативные) наборы признаков (коэффициентов разложения) для определенного класса сигналов. При этом имеется принципиальная возможность создания в перспективе автоматизированных компьютерных систем распознавания, анализа и диагностики объектов в разных предметных областях.

Таким образом, аналитическое описание проекций предъявляемых изображений отрезками ортогональных рядов позволяет при относительно небольших вычислительных затратах использовать в полной мере силу аналитических методов в задачах распознавания в широком смысле. Кроме того, адаптивное аналитическое описание проекций приводит к

резкому уменьшению объема представления данных, то есть к «сжатию» данных, но при этом позволяет вести полную обработку данных в «сжатом» виде через коэффициенты разложения.

В настоящее время активно создается «алгебра» коэффициентов разложения. Достаточно простые соотношения между первичными коэффициентами и коэффициентами разложения для определения по ним производных от сигнала, первообразных и других операций с анализируемыми сигналами. Такие соотношения желательно выводить для каждого базиса. Это существенно расширяет возможности метода, увеличивает его универсальность. Работа выполняется при поддержке проектов РФФИ № 04-02-17368, № 04-01-00756.

Литература

1. 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
2. Классические ортогональные базисы в задачах аналитического описания и обработки информационных сигналов: Учебное пособие/ Ф.Ф.Дедус, Л.И.Куликова, А.Н.Панкратов, Р.К.Тетуев. Под ред. Ф.Ф.Дедуса. - М.: Издательский отдел Факультета ВМиК МГУ им. М.В.Ломоносова, 2004

Резонансно – импедансный метод диагностики одномерных акустических систем

А.В. Держузов, С.А. Махортых

Институт математических проблем биологии РАН

Введение. Постановка задачи

В настоящее время при решении ряда практических задач диагностики, калибровки, оценивания параметров системы и т.д. находят широкое применение всевозможные акустические резонансно – частотные подходы. Общий принцип использования этих методов основан на резком увеличении амплитуды вынужденных колебаний в колебательной системе, при приближении частоты периодического внешнего воздействия к одной из собственных частот системы. Одной из областей использования предлагаемых методов является круг задач акустического каротажа (АК).

Использование спектральных методов, то есть разложений сигнала в ортогональные ряды для практических задач неразрушающего дистанционного контроля основано на значительной чувствительности гармоник разложения к величинам оцениваемых параметров. Помимо связанной с последним обстоятельством точности и надежности получаемых результатов, в ряде случаев эти методы существенно проще и

дешевле традиционных контактных методов. Успешность использования спектральных методов во многом зависит от точности физической модели процесса, поэтому обработка данных тестирования обычно ведется параллельно с моделированием физической системы

Исследование резонансных свойств линейных акустических систем

В качестве примера применения резонансно-импедансного метода к решению практических задач акустики приведем отклик одномерной конечной акустической системы - цилиндрической трубы (заполненной жидкостью скважины) на импульсное акустическое воздействие (на рис. 1 показаны исходный сигнал и его аппроксимация отрезком ортогонального ряда). В системе возникают затухающие колебания на дискретном наборе собственных частот. Их величина, а также декремент затухания колебаний является функцией параметров системы. Наличие дискретного спектра является дополнительным аргументом в пользу применения ортогональных разложений в задаче параметрической идентификации.




Рис. 1. Исходный сигнал низкочастотного акустического каротажа скважины и его аппроксимация отрезком ортогонального ряда.

В качестве математической модели рассматриваемой системы была предложена модель ограниченной «узкой трубы» с резонатором Гельмгольца в зоне локальной аномалии. Так как размеры трубы ограничены, то в результате приложения внешнего импульсного воздействия на трубу образуются стоячие волны определенных дискретных частот – собственные колебания системы, коэффициент затухания которых определяется характеристиками локальной аномалии и параметрами системы. В нашем случае полагаем, что труба закрыта с двух сторон жесткими крышками, что определяет соответствующие граничные условия.

Представление колебаний в акустической системе

Для представления свободных колебаний в системе (трубе) используют суперпозицию ее собственных колебаний, взятых с теми или иными амплитудами. Такое представление позволяет вместо волн с заданной зависимостью от времени рассматривать гармонические составляющие, что удобно ввиду сохранения ими своей временной зависимости. Для получения данного вида представления колебаний системы (трубы) используют спектральные разложения Фурье.

Однако известно, что использование классического анализа Фурье не всегда корректно или оптимально. Причина этого, как правило, связана с природой рассматриваемых сигналов (прежде всего нестационарностью, большим уровнем помех), которые не могут быть полным образом описаны базисными гармоническими функциями. В этом случае предлагается осуществлять выбор базисных функции, которые были бы наиболее адекватны характеристикам рассматриваемой акустической волны. Исходя из того, что волна в трубе экспоненциально затухает, то в качестве базисных функции удобно использовать обобщенные полиномы Лагерра (далее будем называть полиномами Сонина – Лагерра).

На рис. 2 представлены коэффициенты разложения функции давление волны $P(t)$ в верхней точке скважины. При этом цифрой 1 обозначены коэффициенты разложения в случае отсутствия резонанса, а цифрой 2, когда резонанс присутствует.




Рис. 2. Коэффициенты разложения функции давление волны $P(t)$ по обобщенным полиномам Лагерра в верхней точке скважины: 1 – случай отсутствия резонанса, 2 – случай резонансного рассеяния.

Для повышения чувствительности предлагаемого резонансно – импедансного метода диагностики к резонансным гармоникам алгоритм

настраивался подбором оптимального значения масштабного множителя в определении полинома по вышеописанной методике. При выбранных значениях параметров системы оптимальное значение масштабного множителя $m_{opt} = 2,05$.

Работа выполнена при поддержке РФФИ РФФИ (проекты 04-02-17368, 04-01-00756).

Реализация некоторых операций над отрезками ортогональных рядов полиномов Кравчука

О.С. Джунгурова
(Москва)

Введение

Появление электронных вычислительных машин спровоцировало бурное развитие многих областей математики. Одной из таких областей, бесспорно, является теория представления функций в виде ортогональных рядов. Однако потенциал этого математического аппарата остается по-прежнему не раскрытым в полной мере.

Многочисленные исследования показывают, что решение целого ряда практических задач будет проще находить, оперируя с ортогональными представлениями, а не со значениями функций. Однако применение таких подходов на практике изначально требует целенаправленного развития соответствующей аналитической базы и, прежде всего, ответа на вопросы:

– каким образом операции над коэффициентами разложения функций соответствуют различным преобразованиям самих функций?

– каким образом можно понизить алгоритмическую сложность при реализации соответствующих операций на практике?

Далее в докладе будем рассматривать функции, представленные в виде отрезков ортогональных рядов вида

$$f(x_i) = \sum_{n=0}^{N^*} C_n K_n^{(p)}(x_i),$$

где C_n – коэффициенты разложения функции $f(x)$ при $0 < x < N$,

$K_n^{(p)}(x_i)$ – ортогональные полиномы Кравчука параметра $0 < p < 1$, представленные на равномерной решетке: $x_i = 0..N$.

Нам известно, согласно [1], что для полиномов Кравчука справедливы следующие рекуррентные соотношения:

$$\Delta K_n^{(p)} \stackrel{n \ll N}{\approx} K_{n-1}^{(p)},$$

$$xK_n^{(p)} = \alpha_n K_{n+1}^{(p)} + \beta_n K_n^{(p)} + \gamma_n K_{n+1}^{(p)},$$

где $\alpha_n = n + 1$, $\beta_n = n + p(X - 2n)$, $\gamma_n = p(1 - p)(X - n + 1)$.

В данном докладе будет показано, каким образом подобные рекуррентные соотношения можно использовать на практике для преобразований функций путем простейших операций над коэффициентами разложения.

Операции над коэффициентами разложения, тождественные некоторым преобразованиям функций

Обозначим коэффициенты разложения функций $f_1(x)$ и $f_2(x)$ через $\{C_n^*\}$ и $\{C_n^{**}\}$ соответственно. Тогда, на основании уже известных нам рекуррентных соотношений, мы можем найти аналитическую связь между некоторыми преобразованиями функций и операциями над коэффициентами разложения:

Таблица 1. Соответствие некоторых преобразований функций и операций над коэффициентами разложения.

№	Преобразования функций	Операции над коэффициентами разложения
1	$f = \alpha f_1$	$C_n = \alpha C_n^*$
2	$f = f_1 + f_2$	$C_n = C_n^* + C_n^{**}$
3	$f = f_1'$	$C_n \approx C_{n+1}^*$
4	$f = \int f_1 dx$	$C_n \approx C_{n-1}^*$
5	$f = xf_1$	$C_n = \gamma_{n+1} C_{n+1}^* + \beta_n C_n^* + \alpha_{n-1} C_{n-1}^*$

Действия по преобразованию, присваиванию коэффициентов разложения можно схематически отобразить в виде коммутативных диаграмм (рис. 1). Заметим, что часто операции, реализующие различные преобразования функций и полученные на основе рекуррентных соотношений, оказываются сродни моделированию различных физических, химических процессов. Например, дифференцирование функций в данном случае и умножение на переменную можно было бы предложить называть, по аналогии, соответственно переносом и диффузией коэффициентов разложения.

Проанализировав полученные соотношения, приходим к выводу о линейной алгоритмической сложности вычислений по времени

исполнения и по объему требуемой памяти. Однако на практике работу таких алгоритмов можно значительно ускорить, воспользовавшись очевидной возможностью распараллеливания данных процессов.




Рис. 1. Характер изменения коэффициентов в зависимости от преобразования.

Некоторые преобразования функций, встречаемые как в теории, так и в практических задачах, легко могут быть представлены через приведенные выше операции. Приведем пример вычисления коэффициентов разложения (рис. 2), соответствующий следующей аналитической зависимости функций:

$$f = \int (\alpha f_1' + x^2 f_2) dx .$$




Рис. 2. Операционное вычисление коэффициентов разложения некоторой функции.

Заключение

Нами показана возможность реализации некоторых преобразований функций, представленных в виде ортогональных рядов по полиномам Кравчука, в пространстве коэффициентов разложения и предложена принципиальная схема вычислительного процесса. Полученные результаты будут полезны при создании на основе спектральных методов требуемого математического аппарата обработки информационных массивов.

Литература

1. Дедус Ф.Ф., Куликова Л.И., Панкратов А.Н., Тетуев Р.К. «Классические ортогональные базисы в задачах аналитического описания и обработки информационных сигналов» М.: Московский государственный университет им. М.В. Ломоносова, Факультет Вычислительной математики и кибернетики, 2004.

Оценивание VCD семейств алгоритмов на основе колмогоровской сложности

В.И. Донской
(Симферополь)

Введение и основные определения

Доказано [1], что сложность $K_l(S)$ класса S алгоритмов распознавания, определяемая ниже на основе колмогоровского подхода, является мажорантой емкости этого класса: $VCD(S) \leq K_l(S)$. Для сложности $K_l(S)$ гораздо легче получать верхние оценки, чем непосредственно для $VCD(S)$. Если получена оценка $H(S)$ такая, что $K_l(S) \leq H(S)$, то она, очевидно, будет верхней оценкой $VCD(S)$.

Обозначим S - класс алгоритмов, из которого могут извлекаться решающие правила $A \in S$ вида $A: X^n \rightarrow \{0,1\}$; $X^n = \{X = (x_1, \dots, x_n) : x_i \in \{0,1, \dots, 2^M - 1\}\}$. Выборка, состоящая из l элементов множества X^n , обозначается $\tilde{X}_l = X_1, \dots, X_l$ и представляет собой упорядоченный набор $n \times l$ чисел из расширенного натурального ряда. Множество всех выборок обозначается X^l ; множество $\{0,1\}^*$ строк из нулей и единиц любой длины обычным способом представляет числа $0,1,2, \dots$. Длина слова $p \in \{0,1\}^*$ обозначается $len(p)$. Класс частично рекурсивных функций обозначается $P_{p.r.}$.

Определение. 1° Сложность алгоритма A относительно выборки \tilde{X}_l по частично рекурсивной функции U есть

$$K_U(A | \tilde{X}_l) = \begin{cases} \min len(p) : U(p, \tilde{X}_l) = y; \\ \infty, \text{ если } \forall p \in \{0,1\}^* U(p, \tilde{X}_l) \neq y, \end{cases}$$

где $y = A(X_1), \dots, A(X_l)$ - двоичное слово (строка) длины l .

2° Сложность алгоритма A на множестве X^l по частично рекурсивной функции U есть

$$K_{U, X^l}(A) = \begin{cases} \max_{\tilde{X}_l \in X^l} K_U(A | \tilde{X}_l), & \text{если } \forall \tilde{X}_l \in X^l \quad K_U(A | \tilde{X}_l) < \infty; \\ \infty, & \text{если } \exists \tilde{X}_l \in X^l : K_U(A | \tilde{X}_l) = \infty. \end{cases}$$

3° Сложность класса алгоритмов S на множестве X^l по частично рекурсивной функции U есть

$$K_{U, X^l}(S) = \begin{cases} \max_{A \in S} K_{U, X^l}(A), & \text{если } \forall A \in S \quad K_{U, X^l}(A) < \infty; \\ \infty, & \text{если } \exists A \in S : K_{U, X^l}(A) = \infty. \end{cases}$$

4° Сложность класса алгоритмов S на множестве X^l есть

$$K_l(S) = \min_{U \in P_{p.r.}} K_{U, X^l}(S).$$

Согласно колмогоровскому подходу, сложность класса алгоритмов S определяется наименьшей длиной слова (программы) p^* , по которому при помощи соответствующей частично рекурсивной функции (внешнему алгоритму) U^* можно определить слово $y = A(X_1), \dots, A(X_l)$ в наиболее «трудном» (на множестве выборок X^l и алгоритмов S) случае. Очевидно, $K_l(S) \leq K_{U, X^l}(S)$ для произвольной функции $U \in P_{p.r.}$, поэтому для оценивания $K_l(S)$ сверху в качестве алгоритма U может быть взята, например, машина Тьюринга MT , вычисляющая $y = MT(p, \tilde{X}_l)$ или подходящая программа π на каком-нибудь языке программирования такая, что $\pi(p, \tilde{X}_l) = y$ для входа (p, \tilde{X}_l) , и тогда $VCD(S) \leq len(p)$.

$pVCD$: метод программирования оценки VCD

Подход к оцениванию VCD на основе соотношения $VCD(S) \leq len(p) : U(p, \tilde{X}_l) = y = (A(X_1), \dots, A(X_l))$ называется

методом программирования оценки VCD , сокращенно - $pVCD$. Вводится обозначение $len(p) = pVCD(S)$. Этапы реализации $pVCD$ состоят в следующем.

1° Изучение класса S и определение как можно меньшей совокупности свойств (параметров, структурных особенностей) этого класса, указания значений которых достаточно, чтобы сформировать из них слово p_A , описывающее произвольный алгоритм $A \in S$. Предъявить алгоритм U (машину Тьюринга, частично рекурсивную функцию, программу для конечного компьютера) такую, что $\forall A \in S \exists p_A : U(p_A, \tilde{X}_l) = (A(X_1), \dots, A(X_l))$.

2° Определение максимальной длины $len(p_A)$ слова p_A , $A \in S$, как оценки $VCD(S)$ сверху.

Метод $pVCD$ предполагает конструирование сжатого описания p всего класса S и указания алгоритма U , обрабатывающего вход (p, \tilde{X}_l) . В частности, достаточно очевидности существования такого алгоритма, но в общем случае применение $pVCD$ требует искусства программирования и организации данных p .

Сужая круг решающих правил до реализуемых на компьютерах разрядности M , можно получить оценку $pVCD(S)$ с указанием констант. В таблице 1 приведены примеры применения $pVCD$.

Таблица 1. Примеры применения $pVCD$

Класс алгоритмов S	Ранее известная оценка $VCD(S)$	Оценка $pVCD(S)$
Бинарные деревья решений (БРД)	$\mu \log(n\mu)$ (не более μ листьев)	$(\mu - 1) \log(n\mu)$
БРД с линейными предикатами в вершинах (BSP)	-	$(\mu - 1) \times$ $\times (\log(n\mu) + M(n + 1))$
Нейронные сети с k вершинами в одном скрытом слое	$(2kn + 4k + 2) \times$ $\times \log(e(kn + 2k + 1))$	$M(nk + 2k + 1)$

Литература

1. Донской В.И. Колмогоровская сложность классов общерекурсивных функций с ограниченной емкостью // Таврический вестник информатики и математики. КНЦ НАН Украины, 2005. С. 25-34.
2. www.ccas.ru/frc/papers/donskoy05kolmogorov.pdf

Об одном подходе к решению задач из области ВСІ

А.Г. Дьяконов

(Москва)

В настоящее время интенсивно развивается новый подход к проблеме коммуникации человек-ЭВМ – Brain Computer Interface (BCI) [1]. Основная идея этого подхода состоит в следующем. Во время своей активности человеческий мозг генерирует электрические и магнитные поля. С помощью анализа этих полей можно делать выводы о ментальных состояниях головного мозга и использовать «физиологические сигналы» для управления механизмами и приборами.

Для измерения электрического поля достаточно измерить разности потенциалов между электродами, прикреплёнными к скальпу. Есть различные методы снятия сигнала: electroencephalography (EEG), electrocorticography (ECoG), и т.д. Они отличаются характеристиками принимаемого сигнала (частота, отношение «полезный сигнал/шум»), инвазивностью (имплантация электродов в кору), размерами электродов, покрываемой площадью (количество нейронов, которые влияют на сигнал, снимаемый с помощью одного электрода).

Для оценки современных методов распознавания в ВСІ проводятся различные конкурсы, в которых предлагается классифицировать реальные данные (см. [2], [3]). В докладе описан один из подходов к решению задач ВСІ, который занял третье место на конкурсе BCI Competition III (на данных Data set I [Tübingen] среди 27 участников). Основная специфика этого конкурса – обучающая и контрольная выборки были сформированы в различные дни (с интервалом в 1 неделю). Человеческий мозг в эти дни мог показывать разную электрическую активность. Кроме того, электроды могли находиться в разных положениях (быть чуть смещёнными), могли немного измениться сопротивления проводников в системе обработки сигнала и т.д. Во время эксперимента объект выполнял два вида мозговой деятельности. Электрическая активность его головного мозга определялась с помощью ECoG-платиновой сетки из 64 электродов размера 8×8 см. Сигналы записывались в течение 3 секунд с частотой 1000МГц. В первый день было снято 278 записей мозговой активности.

Таким образом, в обучении было 278 объектов, которые описывались с помощью 3000×64 признаков (64 временных ряда по 3000 точек в каждом), 2 класса (предположительно непересекающихся) [4]. Контрольная выборка

состояла из 100 объектов.

Для решения задачи проводились эксперименты с различными эвристиками, переводящими информацию, снятую на электроде в вещественную информацию. При этом эффективность эвристик оценивалась по двум параметрам:


1. Разрешимость задачи распознавания, в которой признаки были сгенерированы этой эвристикой (имеется в виду процент распознавания простейшими алгоритмами).

2. Устойчивость эвристики (слабое изменение разрешимости задачи при небольших изменениях входных данных; например, при «прореживании» временных рядов).

Кроме того, рассматривались также признаки, полученные линейной комбинацией эвристик. Наилучшими оказались эвристики, которые оценивают скорость изменения активности головного мозга во время эксперимента.

Для более эффективной оценки скорости изменения активности, временные ряды изначально преобразовывались методом скользящего среднего (для усреднения шума на соседних точках временного ряда). После отбора «хороших эвристик» были отобраны «хорошие электроды», сигналы с которых при переводе в вещественную (признаковую) информацию порождают хорошо поставленную задачу распознавания.

Данные были визуализированы, и простым просмотром двухпризнаковых подзадач были выбраны методы разделения для каждой из этих подзадач. Интересно, что при этом контрольные объекты располагались «в стороне» от обучающих, однако формы кластеров были похожи (см. рис.).



Для каждой двухпризнаковой задачи обучающие объекты были разделены гиперплоскостью, которая смещением трансформировалась в гиперплоскость для разделения контроля. После этого комитетом большинства проводилось голосование по отнесению контрольного

объекта к одному из двух классов.

С помощью предложенного метода 86% контрольных объектов было верно распознано. Отметим, что средний процент правильного распознавания на контроле, показанный участниками соревнования – 70,4%. В отличие от многих стандартных методов для задач BCI, предложенный подход является очень наглядным и предоставляет возможность выбора методов распознавания, ориентированных на обучающую информацию.

Работа выполнена при финансовой поддержке РФФИ (05-01-00332), Минобрнауки РФ (НШ-1721.2003.1), программы фундаментальных исследований ОМН РАН «Алгебраические и комбинаторные методы математической кибернетики».

Литература

1. José del R. Millán. Brain-computer interfaces. In M.A. Arbib (ed.), “Handbook of Brain Theory and Neural Networks, 2nd ed.” Cambridge: MIT Press, 2002
2. Benjamin Blankertz, Klaus-Robert Müller, Gabriel Curio, Theresa M. Vaughan, Gerwin Schalk, Jonathan R. Wolpaw, Alois Schlögl, Christa Neuper, Gert Pfurtscheller, Thilo Hinterberger, Michael Schröder, and Niels Birbaumer. The BCI competition 2003: Progress and perspectives in detection and discrimination of EEG single trials. *IEEE Trans. Biomed. Eng.*, 51(6):1044-1051, 2004.
3. http://ida.first.fraunhofer.de/projects/bci/competition_iii/index.html
4. Thomas Lal, Thilo Hinterberger, Guido Widman, Michael Schröder, Jeremy Hill, Wolfgang Rosenstiel, Christian Elger, Bernhard Schölkopf, Niels Birbaumer. Methods Towards Invasive Human Brain Computer Interfaces. *Advances in Neural Information Processing Systems (NIPS)*, 2004.

О сложности нахождения элементарных классификаторов в логических процедурах распознавания и классификации

Е.В. Дюкова, А.С. Инякин

(Москва)

Рассматривается задача нахождения информативных фрагментов описаний обучающих объектов (элементарных классификаторов), возникающая при построении логических процедур распознавания и классификации. Данная задача решается на основе поиска неприводимых покрытий булевой матрицы размера $m \times n$. Исследуется вычислительная сложность такого решения. Вводится понятие эффективного (в типичном случае) алгоритма. Каждый шаг такого алгоритма полиномиален относительно размера матрицы и отношение числа всех шагов алгоритма к числу всех неприводимых покрытий почти всегда асимптотически не

превосходит полинома от размера матрицы. Если указанное отношение почти всегда асимптотически равно 1 (т.е. число шагов алгоритма почти всегда асимптотически совпадает с числом неприводимых покрытий), то алгоритм называется асимптотически оптимальным.

Для случая $m^\alpha \leq n \leq 2^{m^\beta}$, $\alpha > 1$, $\beta < 1$, в [1] построен асимптотически оптимальный алгоритм поиска всех неприводимых покрытий булевой матрицы, основанный на перечислении всех ее единичных подматриц, в [2] построен асимптотически оптимальный алгоритм, основанный на построении только тех единичных подматриц, которые порождают неприводимые покрытия.

В настоящей работе показано, что при поиске «коротких» неприводимых покрытий (т.е. покрытий, длины которых не превосходят $\log_2 m - \log_2 \ln \log_2 m - 1$) эффективен практически любой алгоритм с полиномиальной задержкой на каждом шаге, в частности, алгоритм, основанный на переборе всех коротких наборов столбцов.

Кроме того, для случая $n^\alpha \leq m \leq 2^{n^\beta}$, $\alpha > 1$, $\beta < 1$, получена асимптотика для числа «совместимых» наборов столбцов булевой матрицы, т.е. таких наборов столбцов, которые не содержат одинаковых и охватывающих столбцов. Получена асимптотика для числа «совместимых» наборов столбцов являющихся покрытиями. Указанные асимптотики важны для оценки вычислительной сложности алгоритма спуска [5] и его модификации, использующей пошаговое удаление столбцов и строк.

Перейдем к более подробному изложению полученных результатов.

Пусть M_{mn} - множество всех матриц размера $m \times n$ с элементами из $\{0, 1\}$ и пусть $L \in M_{mn}$.

Определение. Набор H из r различных столбцов матрицы L называется покрытием, если подматрица L^H матрицы L , образованная столбцами набора H , не содержит нулевую строку.

Определение. Набор из r столбцов H матрицы L , являющийся покрытием, называется неприводимым покрытием, если подматрица L^H содержит единичную подматрицу порядка r .

Определение. Набор H из r столбцов матрицы L называется совместимым, если любые два столбца набора H содержат единичную подматрицу порядка 2.

Если H - неприводимое покрытие матрицы L , то, очевидно, H - совместимый набор.

Пусть φ - отрезок вида $[q_1, q_2]$, где $q_1 \geq 1$, $q_2 \leq n$. Обозначим через $C_\varphi(L)$, $B_\varphi(L)$ и $U_\varphi(L)$ соответственно множество покрытий, множество неприводимых покрытий и множество совместимых наборов столбцов матрицы L длины которых принадлежат φ . Положим $V_\varphi(L) = U_\varphi(L) \cap C_\varphi(L)$.

Пусть $G(L)$ - конечная совокупность наборов столбцов матрицы L содержащая $B_\varphi(L)$. Предполагается, что каждый набор в $G(L)$ не содержит одинаковых столбцов, и некоторые наборы столбцов в $G(L)$ могут встречаться более одного раза. Число наборов в $G(L)$ обозначим через $|G(L)|$.

Пусть алгоритм A строит покрытия из $B_\varphi(L)$ путем последовательного просмотра всех наборов из $G(L)$. При этом каждый набор из $G(L)$ просматривается столько раз, сколько раз он встречается в $G(L)$. Таким образом, на каждом шаге алгоритма A строится некоторый набор столбцов H из $G(L)$ и проверяется принадлежность H к $B_\varphi(L)$. Совокупность $G(L)$ назовем погружением алгоритма A . Число шагов алгоритма A равно $|G(L)|$.

Нас будет интересовать вычислительная сложность алгоритма A в типичном случае (для почти всех булевых матриц размера $m \times n$).

Будем говорить, что алгоритм A строит погружение $G(L)$ с полиномиальной задержкой, если на каждом шаге выполняется не более $d(m, n)$ элементарных операций и $d(m, n)$ ограничено сверху полиномом от m и n . При этом под элементарной операцией понимается просмотр одного элемента матрицы L .

Определение. Алгоритм A является эффективным, если A строит погружение $G(L)$ с полиномиальной задержкой и для почти всех матриц L из M_{mn} выполнено

$$\lim_{n \rightarrow \infty} \frac{|G(L)|}{|B_\varphi(L)|} \leq \tau(m, n),$$

где $\tau(m, n)$ ограничено сверху полиномом от m и n .

Если $\tau(m, n) = 1$, то алгоритм A называется асимптотически оптимальным.

Пусть $\varphi_0 = [1, n]$, $\varphi_1 = [\log_2 mn, n]$.

Теорема 1. Если $n^\alpha \leq m \leq 2^{n^\beta}$, $\alpha > 1$, $\beta < 1$, то для почти всех матриц L из M_{mn} при $n \rightarrow \infty$ справедливо

$$|U_{\varphi_0}(L)| \approx 2^n.$$

Теорема 2. Если $n^\alpha \leq m \leq 2^{n^\beta}$, $\alpha > 1$, $\beta < 1$, то для почти всех матриц L из M_{mn} при $n \rightarrow \infty$ справедливо

$$|V_{\varphi_0}(L)| \approx |C_{\varphi_0}(L)| \approx |C_{\varphi_1}(L)| \approx |V_{\varphi_1}(L)| \approx \sum_{r \in \varphi_1} C_n^r.$$

Оценка, полученная в теореме 2, является асимптотической верхней оценкой числа шагов алгоритма спуска, использующего пошаговое удаление охватывающих столбцов и строк.

Пусть $r_1 = [\log_2 m - \log_2 \ln \log_2 m - 1]$ (здесь $[x]$ - целая часть x), $\varphi_2 = [1, r_1]$.

Теорема 3. Если $\log_2 n = \bar{o}(m)$ и $m \leq 2^{n^\beta}$, $\beta < 1/2$, то для почти всех матриц L из M_{mn} при $n \rightarrow \infty$ справедливо

$$|U_{\varphi_2}(L)| \approx C_n^{r_1},$$

$$|C_{\varphi_2}(L)| \approx |V_{\varphi_2}(L)| \approx |B_{\varphi_2}(L)| \approx C_n^{r_1} (1 - 2^{-r_1})^m.$$

Из теоремы 3 сразу следует, что при поиске неприводимых покрытий, длины которых не превосходят r_1 , эффективны алгоритмы спуска, эффективен также алгоритм, основанный, на переборе всех наборов

столбцов, длины которых не превосходят r_1 , и для последнего $\tau(m, n)$ не превосходит $\log_2^4 m$.

Замечание. При доказательстве теорем 1, 3 использованы результаты, полученные в работах [3, 4].

Работа выполнена при поддержке проекта РФФИ № 04-01-00795 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. Асимптотически оптимальные тестовые алгоритмы в задачах распознавания // Проблемы кибернетики. Вып. 39, М.: Наука, 1982, С. 165-199.
2. Дюкова Е.В. О сложности реализации дискретных (логических) процедур распознавания // Ж. вычисл. матем. и матем. физ. 2004. Т. 44, № 3, С. 551-561.
3. Дюкова Е.В., Инякин А.С. О процедурах классификации, основанных на построении покрытий классов // Ж. вычисл. матем. и матем. физ. 2003. Т. 43, № 12. С. 1910-1921.
4. Дюкова Е.В., Песков Н.В. Поиск информативных фрагментов описаний объектов в дискретных процедурах распознавания // Ж. вычисл. матем. и матем. физ. 2002. Том 42, № 5, С. 741-753.
5. Инякин А.С. Алгоритмы поиска неприводимых покрытий булевых матриц // Сообщения по прикладной математике. М.: ВЦ РАН, 2004. 25с.

Обратная оптимизация в многокритериальных задачах

Г.М. Емельянов, С.А. Попов

(Великий Новгород)

Входные технические параметры X технологического процесса обычно делятся на k неуправляемых, для которых известно распределение вероятностей, и n управляемых. Задачей обратной оптимизации [1] является определение таких интервалов для неуправляемых параметров $x_{i1} \leq x_i \leq x_{i2}$, $i = 1, 2, \dots, k$, и таких значений управляемых параметров $x_{k+1} \div x_{k+n}$, которые обеспечивают принадлежность данного изделия к классу годных на ранней стадии технологического процесса.

Область допустимых значений параметров – критериев годности $Y = \{y_1, y_2, \dots, y_m\}^T$ задается в виде m -мерного параллелепипеда Ω , стороны которого параллельны осям координат y_i . Если известно


преобразование $\mathbf{Y} = \mathbf{F}(\mathbf{X})$, то для заданной точки \mathbf{X} в пространстве технологических параметров можно определить соответствующую точку \mathbf{Y} в пространстве параметров – критериев годности. Если точке \mathbf{X} соответствует точка \mathbf{Y} внутри области Ω ($\mathbf{Y} \notin \Omega$), то данное изделие соответствует требованиям технических условий по этим параметрам. Таким образом, заданная m -мерная область Ω отображается в пространстве технологических параметров в виде $(k+n)$ -мерной области Γ . Если определен образ Γ области Ω , то это позволяет задавать входные технические параметры $\mathbf{X} \notin \Gamma$, которые обеспечивают заведомо годные изделия. Образ Γ обычно имеет сложную форму, поэтому для того, чтобы задавать входные параметры независимо друг от друга, в область Γ нужно вписать параллелепипед Π со сторонами, параллельными осям координат $x_i, i=1, \dots, k+n$, который будет определять независимые допуски на входные параметры. Преобразование $\mathbf{Y} = \mathbf{F}(\mathbf{X})$ представляется в виде многооткликовой модели [2]

$$\mathbf{Y} = \mathbf{F}(\mathbf{B}, \mathbf{X}) + \mathbf{E} \quad (1)$$

где $\mathbf{F}(\mathbf{X}, \mathbf{B}) = \{f_1(\mathbf{X}, \mathbf{B}), \dots, f_m(\mathbf{X}, \mathbf{B})\}^T$ - вектор функций, $\mathbf{X} = \{x_1, \dots, x_{k+n}\}^T$ - вектор входных параметров, $\mathbf{Y} = \{y_1, \dots, y_m\}^T$ - вектор параметров - критериев годности, $\mathbf{B} = \{b_1, \dots, b_l\}^T$ - вектор коэффициентов модели.


Оценки коэффициентов \mathbf{B} определяются на этапе построения модели (1). На рис. 1 иллюстрируется процесс построения области допустимых значений Γ в пространстве входных параметров.

Рис. 1. Получение совместной области допустимых значений Γ входных параметров для двухоткликовой функции: Γ_i - область допустимых значений параметров для критерия y_i ,
 $\Gamma = \Gamma_1 \cup \Gamma_2$.



Если все входные параметры являются управляемыми, то для определения допусков входных параметров необходимо вводить дополнительные ограничения. Можно, например, строить область Π по критерию максимальной относительной ширины интервалов регулирования этих параметров при заданных пределах их изменения. На рис. 2 показан пример построения допустимых интервалов для трех входных управляемых параметров по такому критерию.

Рис. 2. Построение интервалов допустимых значений входных параметров в виде параллелепипеда Π , вписанного в область допустимых значений Γ для трех управляемых параметров и двух откликов.




При наличии как управляемых, так и неуправляемых входных параметров критерием оптимизации D для построения оптимального параллелепипеда Π и расчета значений управляемых параметров является вероятность выхода годных изделий в виде

$$D = \int_{x_{11}}^{x_{12}} \int_{x_{21}}^{x_{22}} \cdots \int_{x_{k1}}^{x_{k2}} \varphi(x_1, x_2, \dots, x_k) dx_1 dx_2 \dots dx_k \Big|_{x_{k+1}, \dots, x_{k+n}}, \quad (2)$$

где $\varphi(x_1, x_2, \dots, x_k)$ - плотность распределения входных параметров.


На рис. 3 показан порядок построения области Π по критерию (2) для двух неуправляемых параметров.

Рис. 3. Построение области допустимых интервалов для двух неуправляемых входных параметров и для двухоткликовой модели, где $\varphi_1(x)$ и $\varphi_2(x)$ - плотности распределения входных параметров x_1 и x_2 соответственно.



Если наряду с неуправляемыми входными параметрами имеются и управляемые технические параметры, то оптимизация по критерию (2) позволяет определить значения этих параметров, обеспечивающие наибольший выход годных. На рис. 4 показан пример определения оптимальных допусков на входные неуправляемые параметры x_1 и x_2 с плотностями распределения φ_1 и φ_2 , и оптимальное значение x_{30} управляемого входного параметра x_3 , обеспечивающего наибольший выход годных по критерию (3).

Рис. 4. Определение допустимых интервалов для двух неуправляемых входных параметров и оптимального значения одного управляемого параметра для двухоткликной модели.



Литература

1. Управление и оптимизация производственно-технологических процессов. / Под ред. Д.В. Гаскарова. СПб.: Энергоатомиздат, 1995. - 301 с.
2. Попов С.А., Ларина М.П. Определение допустимых областей технологических параметров с помощью многооткликных моделей. // Вестник Новгород. гос. ун-та. Сер.: Естеств. и техн. науки. 2004, № 24, с. 24-29

Размерностный подход к анализу метрических конфигураций

А.Н. Ефимов

(Москва)

Метрики – гибкий и важный инструмент решения задач распознавания образов, прогнозирования и интеллектуального анализа данных. В настоящее время известно огромное количество различных метрик, но задача поиска и синтеза новых метрик остается актуальной.

В докладе описывается размерностный подход для модификации произвольной метрики $\rho(x_i, x_j)$ путем введения дополнительного слагаемого. В качестве такого слагаемого рассматривается модуль

разности размерностных характеристик объектов. Размерностная характеристика $\alpha(x_i)$ объекта x_i есть локальная размерность пространства, в котором находится рассматриваемый объект. Тогда исходная метрика $\rho(x_i, x_j)$ модифицируется следующим образом:

$$\rho'(x_i, x_j) = \rho(x_i, x_j) + k \cdot |\alpha(x_i) - \alpha(x_j)|, \quad (1)$$

где k – степень влияния размерностной характеристики объекта на исходную метрику.

Функция

$$\lambda(r) = \sum_{j=1}^N I\{\rho(x_i, x_j) < r\}, \quad (2)$$

где $I\{A\}$ – индикаторная функция события A , называется функцией размерности объекта x_i . Это кусочно-постоянная монотонная возрастающая функция действительного аргумента, значение которой есть количество точек, содержащиеся в окрестности радиуса r .

Для вычисления размерностной характеристики, необходимо задать область локальности, которая определяется наиболее близкими точками к рассматриваемому объекту. В области локальности функция размерности (2) аппроксимируется функцией

$$\lambda_{appr}(r) = Ar^\alpha, \quad (3)$$

где α и A – параметры аппроксимации. Размерностная характеристика объекта есть показатель α аппроксимирующей функции (3).

Главная неоднозначность в процессе оценки локальной размерности состоит в определении области локальности – отрезка $[0, r_0]$ функции размерности (2). В докладе предлагается способ, позволяющий однозначно определить локальную размерность пространства, которым окружен данный объект.

Наиболее близкие точки к рассматриваемому объекту определяют степень роста функции размерности на начальном отрезке $[0, r_0]$. Ограничения задаются из предположений, что функция размерности (2) в области локальности $[0, r_0]$ не имеет сильного изменения степени роста. Таким образом, накладываются ограничения на аппроксимирующую функцию (3):

$$i - 1 < Ar_i^\alpha < i + 1, \quad i = 2, 3, \dots, N - 1, \quad (4)$$

где N – максимальное значение, при котором данная система неравенств имеет непустое решение.

В докладе продемонстрирована работоспособность размерностного подхода к анализу метрических конфигураций, а также методов кластерного анализа данных с использованием размерностной модификации исходной метрики.

Проведенные эксперименты показали, что модификация метрики может улучшить и придать новые свойства решению задачи. Предложенный способ коррекции метрики позволяет находить границу плотных кластеров, а также выявлять уплотнения внутри кластера.

Литература

1. Воронин Ю.А. Начала теории сходства. / Новосибирск: Наука, 1991.
2. Вишик М.И. Фрактальная размерность множеств. // Соросовский образовательный журнал. Математика и механика. Геометрия. 1998. №1.
3. Горелик Г.Е. Размерность пространства: историко-методологический анализ. / М.: Изд-во МГУ. 1983.
4. Balázs Kégl. Intrinsic dimension estimation using packing numbers. / Montreal, Canada, 2003. // <http://citeseer.ist.psu.edu/546551.html>.
5. Zähle M. Local dimensions, average densities and self-conformal measures. / University of Jena, Germany. // <http://citeseer.ist.psu.edu/145925.html>.

Выбор информативного подпространства признаков (Алгоритм GRAD)

Н.Г. Загоруйко, О.А. Кутненко, И.А. Борисова
(Новосибирск)

Введение

Для решения задачи выбора подмножества наиболее информативных элементов из их большого исходного множества может быть использован алгоритм AdDel [1,2]. Он состоит из последовательно сменяющих друг друга процедур добавления (Addition) наиболее информативных и исключения (Deletion) наименее информативных элементов. Алгоритм позволяет указать как состав, так и наилучшее количество характеристик. Кроме того, оказалось, что он полезен и при решении других задач распознавания и прогнозирования.

Ниже описывается алгоритм GRAD, развивающий идеи, на которых основан алгоритм AdDel.

Алгоритм GRAD

Известно, что несколько признаков, каждый из которых не информативен, вследствие особого вида взаимной зависимости могут образовать информативную «гранулу». Мы убедились в этом на таком

простом примере. На генетических данных с исходным числом признаков $N=319$ мы выбирали информативные подпространства, постепенно наращивая их размерность. При $n=2$ были использованы два метода – алгоритм AdDel и метод полного перебора. При этом выяснилось, что полный перебор выявил 6 пар, информативность которых была выше информативности лучшей пары, найденной методом AdDel. В состав всех этих более успешных пар входили признаки, индивидуальная информативность которых была ниже информативности самого информативного признака, выбранного алгоритмом AdDel на первом шаге. В тех же экспериментах было обнаружено, что если все признаки упорядочить по убыванию их индивидуальной информативности, то в составе наиболее информативных пар преобладают признаки с малыми порядковыми номерами.

Из приведенных фактов был сделан следующий вывод: в алгоритмах выбора информативных подсистем нужно применять элементы полного перебора настолько широко, насколько это позволяют машинные ресурсы. В разработанном нами алгоритме GRAD («гранулированный AdDel») метод AdDel работает на множестве G наиболее информативных «гранул», каждая из которых состоит из w признаков, $w=1,2,3\dots W$, предварительно отобранных методом полного перебора. Выбор W нами делался исходя из двух соображений. Первое из них основано на учете ограничений на возможности решения реальных переборных задач на вычислительных машинах распространенного типа. Второе основано на гипотезе о преобладании простых закономерностей над сложными. В итоге нами было выбрано значение $W=3$.

Вопрос о количестве шагов n_1 добавления лучших и исключения n_2 худших признаков («проблема зубцов») в алгоритмах семейства AdDel оставался открытой. Качество рассматриваемых подсистем зависит от неизвестных свойств обучающей выборки (наличие тесно связанных групп признаков, их частота встречаемости и пр.). По этой причине обоснованных аналитических рекомендаций по оптимальному соотношению величин n_1 и n_2 найти не удается. Некоторые практические рекомендации удалось получить из опыта применения разных сочетаний n_1 и n_2 при решении ряда задач. Выяснилось, что выигрывают варианты, в которых соотношение $n_1:n_2=2:1$, а среди них лучшие результаты получены при значениях $n_1=6$, $n_2=3$. Эти параметры были использованы во всех дальнейших экспериментах.

Пусть из N исходных признаков требуется выбрать подсистему из n наиболее информативных признаков, двигаясь в направлении роста n , начиная с $n=1$. Вначале все N признаков упорядочиваются по индивидуальной информативности в список P_0 . При большом значении N полный перебор сочетаний по 2 и по 3 затруднителен. По этой причине

формируется список P1 из $m_1 < N$ признаков, стоявших в начале упорядоченного по информативности списка P0. В экспериментах анализировались генетические данные, содержавшие 35 объектов, разделенных на 2 класса («здоровые» и «больные диабетом») и список P0 из $N=5527$ признаков.

Из списка P1 методом полного перебора формируется список P2, состоящий из m_2 двухместных гранул, и список P3, состоящий из m_3 трехместных гранул. Будем считать гранулы мощности 1, 2 и 3 вторичными признаками, как это делается в методе группового учета аргументов (МГУА) [3]. Величины m_1 - m_3 задавались, исходя из возможности настольного персонального компьютера, и были равны: $m_1=100$, $m_2=100$, $m_3=100$.

Признаковые подсистемы мощности $n > 3$ формировались из этих 300 гранул двумя методами: AdDel и GRAD. Информативность выбираемых подсистем оценивалась по числу правильных результатов при скользящем экзамене обучающей выборки. Тот и другой метод обнаружил большое число подсистем с максимально возможной информативностью. При этом число подсистем, найденных алгоритмом GRAD, существенно превышало число подсистем, найденных алгоритмом AdDel. Кроме того, алгоритм GRAD, даже с учетом временных затрат на первый этап формирования гранулированных вторичных признаков, выигрывает также и по времени, затрачиваемому на поиск одной подсистемы.

В целесообразности использования нескольких информативных подсистем для **построения коллективных решающих правил** мы убедились на примере тех же генетических данных при решении задачи упорядочения пациентов по шкале «здоров-болен». При этом рассматривались не только 35 пациентов, входящих в контрастные классы «здоров» и «болен диабетом», но и 8 пациентов, входящих в промежуточный класс «высокая группа риска».

Значения функции принадлежности усреднялись по разному количеству найденных подсистем признаков. Если при усреднении по нескольким подсистемам (5-10) некоторые пациенты второго промежуточного класса ошибочно размещались среди пациентов первого либо третьего классов, то после усреднения по 51 подсистеме ошибок в порядковых позициях уже не было.

На этих же данных был применен **алгоритм комбинированного типа DX**, в котором строится логическое решающее правило D с одновременным выбором наиболее информативного подпространства признаков X. Известные методы построения логических решающих правил (LRP) [4] фактически основаны на Ad-подходе. Нами использовалась модификация алгоритма LRP, в которой этап расширения числа используемых признаков основан на идее алгоритма AdDel.

Эксперименты показали, что такая модификация (LAD) регулярно дает лучшие результаты, чем исходный алгоритм ЛРП.

Заключение

Алгоритм GRAD представляет собой простое и очень эффективное средство улучшения алгоритмов решения широкого круга задач, связанных с выбором подмножества элементов (как признаков, так и объектов) из большого их исходного множества. Важно подчеркнуть, что, кроме выбора высоко информативных подсистем элементов, он позволяет находить и ответ на трудный и важный вопрос об оптимальном количестве выбираемых элементов.

Работа выполнена при частичной поддержке фонда «Научный потенциал» (грант № 34) и Российского Фонда Фундаментальных исследований (грант № 05-01-00241).

Литература

1. Кутин Г.И. «Методы ранжировки комплексов признаков. Обзор». - Зарубежная радиоэлектроника. - 1981. - № 9. - С.54-70;
2. Загоруйко Н.Г. Прикладные методы анализа данных и знаний. Изд. ИМ СО РАН, Новосибирск, - 1999..
3. Ивахненко А.Г. Применение принципа самоорганизации для объективной кластеризации изображений, системного анализа и долгосрочного прогноза // Автоматика.1986. №1. с.5-11.
4. Лбов Г.С., Старцева Н.Г. Логические решающие функции и вопросы статистической устойчивости решений. Изд. ИМ СО РАН, Новосибирск, 1999, 211с

Эволюционный алгоритм построения моделей «структура-свойство» для молекулярных поверхностей с использованием аппарата нечеткой логики

А.М. Захаров, М.И. Кумсков, Л.А. Пономарева

(Москва)

В работе предложен эволюционный алгоритм построения модели «структура-свойство» для молекул, имеющих укладку в трехмерном пространстве. Вводится нечеткая классификация особых точек молекулярных поверхностей и расстояний между такими особыми точками. Описывается процесс обучения нечеткой нейронной сети особого рода, используемой как для настройки «признакового пространства», так и для построения предсказывающей модели.

Постановка задачи

В последнее время при поиске потенциально биологически активных веществ широкое распространение получили методы «молекулярного докинга» - вычислительного моделирования связывания из двух молекул

комплекса «белок– лиганд». При этом обе молекулы, как правило, представляются в виде молекулярных поверхностей[1] – поверхностей, определенным образом «натянутых» на молекулярный граф[2] и описываемых в каждой своей точке каким-либо набором физико-химических свойств. Далее, на молекулярных поверхностях каким-либо способом выделяются особые точки и, путем попарного сравнения групп из трех-четырёх особых точек, проводится поиск возможных пространственных конфигураций связывания молекул.

Для того чтобы адаптировать методы молекулярного докинга для задачи «структура-свойство», сформулируем (упрощенную) постановку задачи следующим образом:

Будем рассматривать обучающее множество, состоящее из N молекул, каждая из которых отнесена к одному из двух классов активности (активных и не активных молекул). Пусть для каждой молекулы задана ее триангулированная молекулярная поверхность $S_i, i = 1, \dots, N$ (т.е., граф – набор точек в пространстве, соединенных треугольной сеткой), причем для каждой точки известен некоторый набор ее свойств (топологических, физико-химических), представляемый вектором из m численных значений. Требуется построить в рамках заданного класса моделей модель с наибольшей прогностической силой на обучающей выборке с дальнейшей оценкой прогностической силы алгоритма при помощи процедуры скользящего контроля.

Метод решения

Известной моделью биологической активности, используемой как в молекулярном докинге, так и при поиске ККСС-зависимостей, является пространственный треугольник (тетраэдр), у которого вершины имеют заданные локальные свойства, а стороны треугольника (тетраэдра) задаются интервалами расстояний. Если существует 3D-конформация молекулы, «содержащая» такой треугольник, то считается, что она будет обладать заданным биологическим свойством [3, 4].

Исходя из модели «треугольника» (для «тетраэдра» рассуждения проводятся сходным образом), будем строить предсказывающее правило по следующему алгоритму:

1. Выделим на каждой из молекулярных поверхностей S_i каким-либо способом особые точки P_{i1}, \dots, P_{in_i} , которым соответствуют вектора свойств $\bar{x}_{i1} = (x_{i1,1}, \dots, x_{i1,m}), \dots, \bar{x}_{in_i} = (x_{in_i,1}, \dots, x_{in_i,m})$ (заданные в постановке задачи);

2. Рассмотрим какую-либо из «активных» молекул и выберем в ней произвольный треугольник особых точек P_1, P_2, P_3 ;

3. Разделим пространство R^m признаков особых точек на три нечетких кластера с центрами $\bar{x}_{P_1}, \bar{x}_{P_2}, \bar{x}_{P_3}$ и функциями принадлежности $f_1(\bar{x}, \bar{y}), f_2, f_3$, где \bar{x} - вектор признаков особой точки, \bar{y} - вектор параметров, задающих вид функции принадлежности (например, центр кластера, «концентрированность», «вытянутость» функции принадлежности и т.д.);

4. Далее, пусть d_{\max} - максимум по всей выборке из всех возможных евклидовых расстояний между особыми точками одной молекулярной поверхности из обучающей выборки. Так же, как и в п.4., введем на отрезке $[0, d_{\max}]$ дискретизацию (3 класса) расстояний (задающую нечеткие множества), и определим функции принадлежности $g_j(d, \bar{z}), j = 1, 2, 3$ (например, можно ввести классы «малых», «больших» расстояний и т.д.), где d - расстояние, \bar{z} - вектор параметров функции принадлежности. В качестве центров исходных классов расстояний можно выбрать длины сторон треугольника, выбранного в п.2;

5. Для построения предсказывающего правила сконструируем нейронную сеть следующего вида (см. ниже рис. 1);

На вход такая нейронная сеть принимает признаки трех особых точек P_1, P_2, P_3 и расстояния между ними $d_{1,2}, d_{2,3}, d_{1,3}$. Нейроны $f_1, \dots, f_3, g_1, \dots, g_3$ реализуют соответствующие функции принадлежности, а параметры этих функций – являются настраиваемыми весами этих нейронов. Выходной нейрон (выделен серым цветом) является обычным перцептроном, выдающим на выходе одно из значений $\{0, 1\}$: 1 – если треугольник на входе является «порождающим» активность и 0 – если не является.




Рис. 1. Нейронная сеть, реализующая модель биологической активности.

6. Далее, будем подавать на вход нейронной сети все треугольники всех молекул. Если для одной молекулы хотя бы на одном треугольнике получено значение «1», то будем относить ее к классу «активных», в противном случае отнесем ее к классу неактивных;

7. Проведем обучение нейронной сети каким-либо из известных алгоритмов (см., например, в [5]). При этом будет сформировано (новое) признаковое пространство для особых точек, новая классификация интервалов расстояний и новое предсказывающее правило;

8. Окончательно, при необходимости вернемся к п.2. и повторим весь процесс для другого типа «треугольников».

Предложенный подход может быть использован как для порождения новых, так и для оптимизации уже существующих моделей «структура-свойство», построенных каким-либо другим способом.

Литература

1. Lee, B. and F. M. Richards. The interpretation of protein structures: Estimation of static accessibility. / J. Mol. Biol. 1971, №55, pp.379-400.
2. Rouvray D.H. (Ed.) / Computational Chemical Graph Theory. New York, Nova Publ., 1989.
3. Makeev G.M., Kumskov M.I., Svitani'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. pp.795-808.
4. Connolly M.L. Shape complementarity at the haemoglobin alpha-1-beta-1 subunit interface. / Biopolymers, 1986, №25, pp.1229-1247.
5. Bishop, C. Neural Networks for Pattern Recognition. / Oxford University Press, 1995.

Эмпирическое восстановление возможности

А.В. Зубюк
(Москва)

Профессором Пытьевым Ю.П. была поставлена задача: построить метод восстановления неизвестной теоретико-возможностной модели, имеющей стохастический прототип, по результатам серии экспериментов и оценить вероятность ошибки, возникающей при использовании построенного метода.

Формально постановка задачи такова. Пусть задано дискретное (т. е. либо конечное, либо счётное) множество элементарных событий $\Omega = \{\omega_1, \omega_2, \dots\}$, $\mathbf{A} = \mathbf{P}(\Omega)$ — σ -алгебра всех подмножеств множества Ω , на котором для каждого проводимого эксперимента задана вероятность $Pr_i, i = 1, 2, \dots$, характеризуемая вероятностями

элементарных событий $Pr_i(\{\omega_1\}), Pr_i(\{\omega_2\}), \dots$, где i — номер эксперимента. От эксперимента к эксперименту вероятность изменяется таким образом, что максимально согласованная с ней возможность остаётся неизменной, т. е. существует (но не известна) возможность P , максимально согласованная со всеми вероятностями $Pr_i, i = 1, 2, \dots$

Проводятся эксперименты и наблюдаются их исходы $\omega^{(1)}, \omega^{(2)}, \dots$. Пусть также заданы нечёткие величины $\theta: \Omega \rightarrow T$ и $\xi: \Omega \rightarrow X$, и множество D решающих правил $d: X \rightarrow T$. Пусть в D существует единственное правило d_* , минимизирующее возможность ошибки $P(\{\omega \in \Omega: \theta(\omega) \neq d(\xi(\omega))\})$ оценивания величины θ по наблюдению величины ξ . Требуется по результатам $\omega^{(1)}, \omega^{(2)}, \dots$ проводимых экспериментов найти решающее правило \tilde{d}_* , которое будет оценкой правила d_* , и оценить вероятность несовпадения истинного правила d_* и эмпирического решающего правила \tilde{d}_* .

Очевидно, что если бы вероятности $Pr_i, i = 1, 2, \dots$ были известны, то по известному правилу [1,2] можно было бы найти максимально согласованную с ними возможность P , и далее, решив задачу минимизации возможности ошибки оценивания, найти решающее правило d_* . Однако вероятности $Pr_i, i = 1, 2, \dots$ неизвестны. Вместо них было предложено использовать эмпирическую вероятность \tilde{Pr} , для которой вероятности элементарных событий равны частотам появления этих событий в серии из l проведённых экспериментов:

$$\tilde{Pr}(\{\omega_i\}) = \nu_i = \frac{1}{l} \sum_{j=1}^l \chi_i(\omega^{(j)}), \quad \text{где } \chi_i(\omega) = 0, \text{ если } \omega \neq \omega_i \text{ и}$$

$\chi_i(\omega) = 1$, если $\omega = \omega_i$. Далее на основе эмпирической вероятности \tilde{Pr} строится максимально согласованная с ней возможность \tilde{P} , которую также назовём эмпирической, а на её основе строится эмпирическое решающее правило \tilde{d}_* .

Для того, чтобы оценить вероятность ошибочного построения решающего правила при использовании описанного выше метода было

замечено, что $\tilde{d}_* = d_*$, если k_* элементарных событий, имеющих максимальную эмпирическую возможность \tilde{P} , совпадут с k_* элементарными событиями, имеющими максимальную возможность P , а также эмпирические и истинные возможности этих событий будут упорядочены одинаково, где k_* — некоторый номер, определяемый истинной возможностью P и нечёткими величинами θ и ξ . Событие, состоящее в невыполнении последнего условия обозначим E . Из вышесказанного очевидно, что $Pr^{(l)}(\{d_* \neq \tilde{d}_*\}) \leq Pr^{(l)}(E)$, и таким образом оценка вероятности ошибочного построения решающего правила сводится к оценке вероятности ошибочного построения теоретико-возможностной модели проводимых экспериментов, где под ошибкой понимается событие E (здесь l — число проведённых экспериментов, $Pr^{(l)}$ — вероятность, определённая на σ -алгебре всех подмножеств множества $\Omega^l = \Omega \times \dots \times \Omega$ (l раз), такая, что для любого $A \subset \Omega$ $Pr^{(l)}(A \times \Omega \times \dots \times \Omega) = Pr_1(A)$, $Pr^{(l)}(\Omega \times A \times \dots \times \Omega) = Pr_2(A)$, ...).

Получены оценки вероятности ошибки E для случаев, когда вероятности не изменяются от эксперимента к эксперименту, т.е. $Pr_1 = Pr_2 = \dots$. Когда множество Ω конечно, эта оценка

$$Pr^{(l)}(E) \leq 4 \sum_{j=1}^{k-1} \exp\{-l/2 (1 - \sum_{i=1}^{j-1} pr_i - 2pr_j)^2\} +$$

$$4 \sum_{j=1}^{k-1} \exp\{-l/2 (pr_j - pr_{j+1})^2\} \xrightarrow{l \rightarrow \infty} 0, \text{ где } k \text{ — количество}$$

элементарных событий. Для случая счётного Ω

$$Pr^{(l)}(E) \leq 4 \sum_{j=1}^{k_*} \exp\{-l/2 (1 - \sum_{i=1}^{j-1} pr_i - 2pr_j)^2\} +$$

$$4 \sum_{j=1}^{k_*-1} \exp\{-l/2 (pr_j - pr_{j+1})^2\} + 4l \exp\{-l/2$$

$$(pr_{k_*} - pr_{k_*+1})^2\} \xrightarrow{l \rightarrow \infty} 0. \text{ Прямое применение этих оценок}$$

требует хотя бы примерной информации о вероятности $Pr = Pr_1 = Pr_2 = \dots$, а также некоторой информации о номере k_* для случая счётного множества элементарных событий. Для того, чтобы избежать требования дополнительной информации был разработан алгоритм, который, например, для случая конечного множества

элементарных событий, состоит в следующем: последовательно проводить эксперименты до тех пор, пока не выполнится критерий останова, которым является событие

$$\mathbf{K} = \bigcap_{j=1}^{k-1} [\{ |v_j - (1 - \sum_{i=1}^j v_i) - 2\varepsilon_l| \geq \delta_{jl} \} \cap \{ |v_j - v_{j+1}| - 2\varepsilon_l \geq \delta_{jl} \}],$$

где величины ε_l и δ_{jl} определяются наперед задаваемой величиной α . При этом алгоритм работает так, что после его останова и построения указанным выше методом эмпирической возможности \tilde{P} вероятность ошибки не превзойдёт α (т. е.

$Pr^{(l)}(E) \leq \alpha$). Доказано, что вероятность останова алгоритма стремится к единице с увеличением числа проведённых экспериментов (т. е. $Pr^{(l)}(\mathbf{K}) \xrightarrow{l \rightarrow \infty} 1$). Заметим, что аналогичный алгоритм был

разработан и для случая счётного множества элементарных исходов.

В докладе будут рассмотрены отмеченные выше вопросы, а также изложены некоторые результаты, полученные для случая, когда от эксперимента к эксперименту вероятность изменяется. Эта ситуация принципиально отличается от описанных выше тем, что в ней не применимы статистические методы оценивания, проверки гипотез и т. п., однако применимы теоретико-возможностные.

В заключении мне хотелось бы выразить благодарность моему научному руководителю проф. Ю.П. Пытьеву за помощь в решении поставленных задач.

Литература

1. Пытьев Ю.П. Возможность. Элементы теории и применения // Эдиториал УРСС. Москва, 2000. С. 1-100.
2. Pyt'ev Yu.P. Stochastic models of possibility // Pattern Recognition and Image Analysis. 2002. 12(4). P. 376-396.

Оценка индекса системы событий

Е.А. Иванова, С.А. Жданов, В.Л. Матросов

Естественно предположить существование иерархии классов алгоритмов по величине ёмкости в зависимости от сложности их структуры.

Всякая регулярная задача определяет отношение ZF- равносильности на множестве алгоритмов модели, разбивающее её на смежные классы.

Можно полагать, что для всякого алгоритма $A = B \bullet C$ существуют $\tau, \lambda_1, \dots, \lambda_t$ такие, что для $t = 1, \dots, q$ найдется вектор

$\sigma_t = (\sigma_{t1}, \dots, \sigma_{tr}) \in \{0,1\}^\tau$, удовлетворяющий равенству

$$(\Gamma_{ij}, B) = \sum_{j=1}^{\tau} (\sigma_{ij} \bullet \lambda_j), \quad (1)$$

$$\text{где } \tau \leq T = \left[\frac{(Lmn)^{p+1}}{Lmn-1} \right].$$

Теорема 1. Для всякой ZF-подмодели верна оценка индекса системы событий $T(\Lambda)$ $Ind_T^M(\tilde{S}^q) \leq \Theta \cdot \prod_{i=1}^T \left(\sum_{t=1}^{\Theta} \sigma_{it} + 1 \right)$, где величина T и коэффициенты σ_{it} определены в условии (1).

С помощью теоремы 1 легко оценивается ёмкость модели, но она может быть усилена путём уменьшения величины T при использовании операционных многочленов специального вида.

Доказывается усиленный вариант теоремы для случая, когда операционные многочлены являются обычными многочленами над R и с использованием этой теоремы получается оценка ёмкости модели с решающим правилом,

$$C^*(N) = (1, \tilde{C}_2(N)),$$

$$\text{где } \tilde{C}_2(N) = \left(\frac{N}{2} \right)^{q-2} N [q(2mL)^n]^{q-1},$$

не зависящая от показателя степени корректного алгебраического замыкания алгоритмов.

Построение устойчивых интегральных индикаторов

Т.В. Казакова, В.В. Стрижов, В.В. Шакин

(Москва)

При построении интегральных индикаторов большого количества объектов появляется проблема их адекватной сравнимости, так как некоторые отдельные объекты имеют значения показателей, существенно отличающиеся от показателей основного числа объектов. Это означает, что в рамках линейной модели зависимости интегральных индикаторов объектов от значений их показателей объекты-выбросы имеют большее влияние на веса показателей, чем прочие объекты. Существуют два способа решения этой проблемы: исключение подобных объектов из

выборки и разбиение множества объектов на несколько классов, внутри которых производится сравнение. Часто эти способы неприемлемы.

Предлагается нелинейное монотонное отображение значений измеряемых показателей с целью получения устойчивого интегрального индикатора. Это отображение необходимо при анализе сложных структур данных, например, данных, соответствующих элементам декартова произведения множеств «объекты-показатели-отсчеты времени» или «объекты-показатели-местоположения».

Устойчивые интегральные индикаторы были построены в рамках программы социально-гигиенического мониторинга Минздрава РФ. Минздравом осуществляется анализ данных по содержанию контаминантов в продуктах питания. Цели и задачи исследования: 1) выявление продуктов питания, представляющих наибольшую потенциальную опасность для здоровья населения; 2) выявление контаминантов, являющихся приоритетными загрязнителями продуктов питания; 3) выявление экологически неблагоприятных по качеству продаваемых продуктов питания субъектов РФ.

Предоставленные экспертами данные имеют структуру «объекты-показатели-местоположения», то есть задан набор матриц $\widehat{D} = \{D_1, \dots, D_l \mid D_i \in R^{m \times n}\}$, каждый элемент d_{ijk} которого поставлен в соответствие элементу декартова произведения трех множеств этой структуры. Требуется получить три вектора – интегральных индикатора – для каждого из множеств, используя модель линейной зависимости индикаторов от перекодированных значений показателей.

Для приведения показателей к единой шкале в [1] было предложено отображение отрезка $[\min_i d_{ijk}, \max_i d_{ijk}]$ в отрезок $[0, 1]$. Рассмотрим параметрическое отображение ρ из фиксированного множества отображений: билинейное отображение и функции распределения равномерного, нормального и экспоненциального распределений.

Выбор конкретного вида функции определяется характером распределения исходных данных.

Для оценки параметров введем функционал качества S . Используем алгоритм скользящего контроля.

Рассмотрим отображение $D \rightarrow A$, где $D = \langle \mathbf{d}_1, \dots, \mathbf{d}_n \rangle$ – матрица исходных данных и $A = \langle \mathbf{a}_1, \dots, \mathbf{a}_n \rangle$ – матрица перекодированных данных. Вектор-столбец \mathbf{a}_j есть результат отображения $\mathbf{a}_j = \rho_j(\theta, \mathbf{d}_j)$, где $\rho_j \in P$ и θ – вектор параметров функции ρ_j . Параметры оцениваются

как $\Theta = \arg \min_{\theta \in B} s(\Theta, Q)$. Вектор Θ есть присоединенные векторы $\langle \theta_1, \dots, \theta_n \rangle$, Q – матрица интегральных индикаторов, полученная следующим образом. Пусть \mathbf{q}_i есть интегральный индикатор объектов, описанных матрицей A при удалении строки, описывающей i -ый объект. Тогда $Q = \langle \mathbf{q}_1, \dots, \mathbf{q}_n \rangle$. Значения индикаторов удаленных объектов на диагонали матрицы заменяются средним значением по строкам. Функционал качества интегрального индикатора $s = \lambda_1$, где $\lambda_1, \dots, \lambda_r$ – сингулярные числа в разложении $Q = U \Lambda V^T$. Область поиска B параметров задана.

Вычисление интегрального индикатора происходит на основе обобщения метода сингулярного разложения матрицы по следующей схеме: выбираем максимальный по норме вектор \mathbf{a}_1 длины n и вектор \mathbf{b}_1 длины m , записанный в виде строки. i -ая координата вектора \mathbf{c}_1 вычисляется по формуле $c_1^{(i)} = \frac{(A_i, \mathbf{b}_1^T \mathbf{a}_1)}{(\mathbf{b}_1^T \mathbf{a}_1, \mathbf{b}_1^T \mathbf{a}_1)}$, где $A_i \in R^{m \times n}$, $i = \overline{1, l}$ – матрицы в пространстве объекты-показатели. Определим скалярное произведение матриц следующим образом $X = \{x_{ij}\}_{i,j=1}^{m,n}$, $Y = \{y_{ij}\}_{i,j=1}^{m,n}$,

$$(X, Y) = \sum_{i,j=1}^{m,n} x_{ij} y_{ij}. \text{ Далее}$$

$$a_k^{(i)} = \frac{(A_i, \mathbf{b}_{k-1}^T \mathbf{c}_{k-1})}{(\mathbf{b}_{k-1}^T \mathbf{c}_{k-1}, \mathbf{b}_{k-1}^T \mathbf{c}_{k-1})},$$

$A_i \in R^{m \times l}$, $i = \overline{1, n}$ – матрицы в пространстве объекты-местоположения;

$$b_k^{(i)} = \frac{(A_i, \mathbf{c}_{k-1}^T \mathbf{a}_k)}{(\mathbf{c}_{k-1}^T \mathbf{a}_k, \mathbf{c}_{k-1}^T \mathbf{a}_k)},$$

$A_i \in R^{l \times n}$, $i = \overline{1, m}$ – матрицы в пространстве местоположения-показатели.

Векторы $\mathbf{a}, \mathbf{b}, \mathbf{c}$ определяются как пределы соответствующих последовательностей $\mathbf{a} = \lim \mathbf{a}_k$, $\mathbf{b} = \lim \mathbf{b}_k$, $\mathbf{c} = \lim \mathbf{c}_k$. В качестве интегральных индикаторов множеств признаки, объекты, местоположения используются векторы $\mathbf{u}, \mathbf{v}, \mathbf{w}$:

$$\mathbf{u} = \frac{\mathbf{a}}{\|\mathbf{a}\|}, \mathbf{v} = \frac{\mathbf{b}}{\|\mathbf{b}\|}, \mathbf{w} = \frac{\mathbf{c}}{\|\mathbf{c}\|}.$$

Предлагаемый метод предварительной обработки данных, учитывая распределения исходных объектов по показателям, уменьшает влияние объектов с существенно отличными значениями показателей. Данное преобразование позволяет получить индикаторы объектов, устойчивые к появлению объектов-выбросов. Обобщение метода сингулярного разложения матрицы дает возможность строить интегральные индикаторы для данных со структурой «объекты-показатели-отсчеты времени» или «объекты-показатели-местоположения».

Данная работа поддержана грантом РФФИ 04-01-00401-а.

Литература

1. Айвазян С.А. Интегральные индикаторы качества жизни населения: их построение и использование в социально-экономическом управлении и межрегиональных сопоставлениях. – М.: ЦЭМИ РАН, 2000. – С. 56.
2. Strijov, V., Shakin, V. Index construction: the expert-statistical method. Environmental research, engineering and management. 2003. No. 4(26). P.51-55. ISSN 1392-1649.

Генетические алгоритмы синтеза алгоритмических композиций в задачах распознавания

Д.Ю. Каневский

(Москва)

Алгебраический подход к проблеме распознавания подразумевает построение корректных алгоритмов в виде композиции некоторого числа базовых эвристических алгоритмов, корректирующей операции и решающего правила [1.2]. Для практического применения данного подхода были разработаны специальные методы, основанные на последовательной оптимизации базовых алгоритмов [1.1]. Последовательная оптимизация — это, по сути дела, «жадная» стратегия, при которой каждый следующий алгоритм настраивается на компенсацию ошибок, допущенных предыдущими алгоритмами. Аналогичная стратегия применяется в ряде современных методов взвешенного голосования, таких, как бустинг (boosting), баггинг (bagging) и метод случайных подпространств (Random Subspace Method, RSM) [1.3].

В данной работе предлагается новый метод построения композиций, в котором все базовые алгоритмы и корректирующая операция настраиваются одновременно. Метод основан на специальном эволюционном алгоритме, называемом кооперативной коэволюцией [1.6]. В рамках данной модели развиваются несколько генетически изолированных популяций, взаимодействующих по принципу симбиоза.

Индивиды каждой популяции кодируют часть решения задачи, а совокупность представителей всех популяций определяет решение в целом. Степень соответствия (fitness) отдельных индивидов, образующих такую совокупность, оценивается исходя из качества решения в целом, что способствует кооперативному взаимодействию индивидов разных популяций.

Модель кооперативной коэволюции представляется достаточно удачным инструментом для синтеза алгоритмических композиций. В данном случае индивиды являются алгоритмами, и от каждой популяции выделяется по одному базовому алгоритму для образования композиции. В соответствии с идеей кооперативной коэволюции качество каждого алгоритма определяется качеством работы всей композиции, в которой он участвует.

Основная идея предлагаемого метода заключается в том, чтобы использовать генетическую оптимизацию для выбора подмножеств объектов и признаков, по которым производится обучение базовых эвристических алгоритмов. При этом каждый базовый алгоритм специализируется на классификации определённой части объектов в определённом подпространстве признаков. Метод применим к произвольным семействам эвристических алгоритмов и корректирующих операций. Высокая степень общности достигается благодаря тому, что генетический алгоритм используется не для оптимизации параметров базовых алгоритмов, а лишь для подбора начальной информации, подаваемой на вход стандартным процедурам их настройки.

Важным достоинством предлагаемого метода является малая мощность получаемых композиций. В ходе эволюции число базовых алгоритмов, образующих композицию, может как увеличиваться, так и уменьшаться. Каждый алгоритм находит свою экологическую нишу, число которых в реальных задачах, как правило, невелико. В то время как обычные «жадные» стратегии набирают по несколько сотен алгоритмов, коэволюционный метод ограничивается 3–6.

Метод рассмотрен более подробно и реализован для случая линейных корректирующих операций и задачи классификации с двумя классами. Качество композиции оценивалось по функционалу среднего отступа (margin) обучающих объектов от разделяющей поверхности [1.5]. Как показал ряд предварительных экспериментов, применение данного функционала существенно улучшает качество классификации по сравнению со стандартным функционалом частоты ошибок на обучающей выборке.

В рамках работы проведены эксперименты на модельных и реальных задачах классификации. В качестве базового семейства алгоритмов использовалось правило Байеса. Для модельных задач в качестве объектов

обучения были рассмотрены выборки из двумерного нормального распределения, для экспериментов на реальных данных были выбраны наугад 12 задач из репозитория UCI [1.4]. Сравнение проводилось с известными алгоритмами построения алгоритмических композиций: bagging, boosting и RSM, также основанными на принципе взвешенного голосования. Во всех модельных задачах предложенный метод показал наилучшие результаты. Результаты расчетов для задач из репозитория UCI представлены в таблице 1. В ней приведены усредненные по 100 запускам проценты ошибок на тестовой выборке. Для коэволюционного метода в скобках указано среднее число алгоритмов в композиции (в остальных методах число алгоритмов фиксировалось и составляло 250). Как видно из таблицы, в 10 из 12 задач предложенный метод показал наилучшие результаты. При этом среднее число алгоритмов в композиции не превышало 6.

В силу высокой стабильности правила Байеса, использованного в качестве базового алгоритма, можно предполагать, что коэволюционный метод уменьшает ошибки классификации за счет уменьшения не только вариации (variation), но и смещения (bias) базовых алгоритмов [1.3].

К недостаткам метода можно отнести высокие вычислительные затраты и нетривиальность настройки параметров генетического алгоритма. Впрочем, эти недостатки присущи большинству генетических алгоритмов.

Предложенный в данной работе метод является новым. Малая изученность и подтверждаемая данными экспериментами перспективность коэволюционного подхода применительно к проблемам распознавания позволяет назвать широкий круг направлений дальнейшей работы по развитию и улучшению данного метода.

Таблица 1. Результаты расчетов для задач из репозитория UCI.

Задача	Баз. алгоритм	Коэв. метод	Бустинг	Баггинг	RSM
Cancer	5.48	4.0 (3.95)	4.44	5.63	5.05
Credit-a-1	15.30	13.37 (4.52)	23.96	15.28	14.78
Credit-a-2	15.87	14.79 (5.23)	18.88	15.86	15.95
Credit-g	32.11	25.42 (2.25)	30.01	31.60	32.29
DBC	11.43	5.61 (5.0)	23.61	11.35	11.44
Heart	19.52	17.59 (3.65)	22.79	19.53	19.26
Hepatitis	16.51	17.64 (3.08)	20.17	16.60	16.57
Liver	37.06	35.59 (1.9)	34.40	37.03	36.84
Diabetes	31.80	23.65 (3.38)	31.62	31.66	30.87
Survival	30.99	26.45 (2.66)	27.11	29.52	28.02
Tic-tac-toe	28.92	20.29 (1.95)	33.17	28.96	27.78
Voting	6.51	5.17 (1.77)	7.1	6.55	6.33

Работа выполнена при поддержке Российского Фонда
Фундаментальных Исследований, проекты 04-07-90290, 05-01-00877.

Литература

1. Воронцов К. В. Оптимизационные методы линейной и монотонной коррекции в алгебраическом подходе к проблеме распознавания // ЖВМ и МФ. — 2000. — Т. 40, No. 1. — С. 166–176.
2. Журавлев Ю. И. Об алгебраическом подходе к решению задач распознавания и классификации. // Проблемы кибернетики. — 1978. — Т.33 — С. 5-68.
3. Bauer E., Kohavi R. An empirical comparison of voting classification algorithms: Bagging, boosting, and variants // Machine Learning. — 1999. — Vol. 36, no. 1-2. Pp. 105–139.
4. Blake C., Merz C. UCI repository of machine learning databases: Tech. rep.: Department of Information and Computer Science, University of California, Irvine, CA, 1998.
5. Mason L. Margins and Combined Classifiers: Ph.D. thesis, Australian National University, 1999.
6. Potter M. A. The Design and Analysis of a Computational Model of Cooperative Coevolution: Ph.D. thesis, Michigan University Press. — 1997.

Методы выделения оптимальной совместной подсистемы системы линейных неравенств

Н.Н. Катериночкина
(Москва)

Решение оптимизационных задач в теории распознавания является одним из важнейших этапов синтеза высокоточных алгоритмов распознавания и прогноза. Одной из таких задач, возникающих в процессе оптимизации некоторых моделей алгоритмов распознавания, является задача выделения из системы линейных неравенств оптимальной совместной подсистемы, обладающей заданными свойствами, например, максимальной по мощности или содержащей максимальное число целых блоков, на которые разбиты неравенства исходной системы, и т.д.

Рассмотрим систему S линейных неравенств вида:

$$\sum_{j=1}^n a_{ij}x_j \leq b_i, \quad i = 1, \dots, m \quad (1)$$

Система S вообще говоря не совместна. Справедливо следующее утверждение.

Лемма 1. Пусть система S имеет ранг r , $r > 0$. Тогда ранг любой нерасширяемой совместной подсистемы системы S также равен r .

Определение 1. Подсистему мощности r и ранга r системы S назовем

r-подсистемой.

Следуя [1], введем ряд понятий, необходимых для дальнейших рассуждений. Рассмотрим, как и выше, систему вида (1) из m линейных неравенств от n переменных. Предположим, что система (1) совместна и имеет ранг r , отличный от нуля.

Определение 2. Решение системы (1) назовем *узловым*, если оно обращает в равенства какие-нибудь r ее неравенств с линейно-независимыми левыми частями.

Определение 3. Подсистему системы (1) назовем *узловой подсистемой*, если ее ранг равен числу неравенств в ней и все ее узловые решения удовлетворяют системе (1).

В [1, гл. 1] доказана следующая теорема.

Теорема 1.1. Каждая совместная система линейных неравенств вида (1) отличного от нуля ранга r имеет хотя бы одну узловую подсистему, а значит, хотя бы одно узловое решение. (При этом каждая узловая подсистема является r -подсистемой.)

Рассмотрим теперь несовместную систему S вида (1). Из леммы 1 и теоремы 1.1 следует

Лемма 2. Пусть система S имеет ранг r , $r > 0$. Тогда каждая нерасширяемая совместная подсистема системы S имеет хотя бы одну узловую r -подсистему.

Поэтому для выделения всех нерасширяемых совместных подсистем системы S достаточно перебрать все ее r -подсистемы. Для каждой из таких подсистем надо решить простую задачу: найти одно ее узловое решение. Для этого все знаки неравенств в подсистеме надо заменить равенствами и найти одно решение полученной системы линейных уравнений. Затем найденное узловое решение подставляется во все неравенства системы S , при этом выделяются те неравенства, которым это решение удовлетворяет. Выделенные неравенства образуют совместную подсистему – расширение рассмотренной r -подсистемы. При этом справедлива следующая

Лемма 3. Пусть B – r -подсистема системы S ранга r , $r > 0$. Если $r < n$, то B имеет множество узловых решений. Тогда при подстановке любого узлового решения B в неравенства системы S получим одну и ту же расширенную совместную подсистему $w(B)$.

Обозначим множество всех r -подсистем системы S через R . Из лемм 2 и 3 следует, что если мы переберем все элементы множества R и описанным выше способом построим их расширения, то мы получим множество W совместных подсистем, среди которых будут все нерасширяемые совместные подсистемы. Среди них можно выбирать оптимальные подсистемы с интересующими нас свойствами, например, максимальные по мощности. Если удастся перебрать в реальное время все

множество R , то находим точное решение задачи. В противном случае, при переборе некоторой части множества R , находим приближенное решение.

Описанный метод сочетает выделение оптимальной подсистемы с одновременным нахождением ее решения, что и является конечной целью задачи оптимизации.

Обозначим через M множество нерасширяемых совместных подсистем системы S . Имеет место следующее соотношение для мощностей множеств R, W, M .

Лемма 4.

$$|M| \leq |W| \leq |R| \leq C_m^r$$

При практической реализации описанного метода рекомендуется сначала преобразовать систему S следующим образом. Сначала нормируем неравенства системы так, чтобы модуль первого ненулевого коэффициента в каждом неравенстве был равен 1 (знаки при этом не меняем). Затем упорядочиваем все неравенства по возрастанию правых частей. И в дальнейшем, при построении r -подсистем, рассматриваем неравенства в этом порядке.

При переборе множества всех r -подсистем можно рассматривать все подсистемы мощности r и отбрасывать те из них, ранг которых меньше r . Но мы рекомендуем строить r -подсистемы поэтапно: сначала выбираем неравенство ранга 1, затем присоединяем к нему такое очередное неравенство, чтобы ранг объединения был равен 2, и т.д. Если уже выбрана i -подсистема, то к ней присоединяем очередное неравенство так, чтобы получилась $(i+1)$ -подсистема, $i = 1, \dots, (r-1)$.

Для задач большой размерности разработан приближенный вариант метода – алгоритм A_w , который осуществляет частичный направленный перебор r -подсистем системы S . Опишем общую схему работы алгоритма A_w .

Алгоритм A_w содержит несколько итераций. Перед первой итерацией система S преобразуется как указано выше: ее неравенства нормируются и упорядочиваются по возрастанию правых частей. На каждой итерации сначала строится из числа допустимых на данном этапе неравенств так называемая базовая r -подсистема B системы S . Это построение производится поэтапно, при этом неравенства выбираются в указанном выше порядке. Затем для подсистемы B строится расширенная совместная подсистема $w(B)$. Для этого находится одно узловое решение подсистемы, это решение подставляется во все неравенства системы S и выделяются те из неравенств, которым оно удовлетворяет. Далее строится множество ассоциированных с B подсистем путем замены в ней некоторых неравенств на неравенства из системы S , не вошедшие в подсистему $w(B)$. К тем из ассоциированных подсистем, которые являются r -подсистемами,

применяется процедура расширения их до некоторой совместной подсистемы системы S . В конце каждой итерации из числа допустимых неравенств исключаются несколько первых по порядку неравенств, вошедших в подсистему B .

Среди всех полученных расширенных совместных подсистем выбирается оптимальная подсистема с интересующими нас свойствами (максимальная по мощности и т.д.). При этом на каждом этапе хранится только одна подсистема, рекордная среди всех, полученных на данный момент. Последняя из них принимается в качестве приближенного решения поставленной задачи.

Приближенный метод работает быстро, так как общее число рассмотренных подсистем не больше, чем $r(m - r)^2 / 2$.

Литература

1. Черников С.Н. Линейные неравенства. М.: Наука, 1968.

Апостериорный подход к решению типовых задач анализа и распознавания числовых квазипериодических последовательностей: обзор результатов

А.В. Кельманов

(Новосибирск)

Условимся говорить, что последовательность выборочных номеров числовой последовательности квазипериодична, если она упорядочена в порядке возрастания номеров и разность между последующим и предыдущим номерами лежит в фиксированном интервале. Фрагментом последовательности назовем любую совокупность подряд расположенных элементов из этой последовательности. Будем говорить, что последовательность выборочных фрагментов квазипериодична, если последовательность номеров первых членов этих фрагментов квазипериодична. Квазипериодическая последовательность – это последовательность, для которой существует такая выборка неперекрывающихся фрагментов, что ее элементы квазипериодичны и каждый фрагмент выборки имеет характерное детерминированное или стохастическое свойство. Примеры детерминированной и стохастической квазипериодических последовательностей приведены на рис. 1.




Рис. 1.

В работе приводится обзор некоторых результатов по исследованию апостериорного (off-line) подхода к решению типовых задач помехоустойчивой обработки (анализа и распознавания) числовых последовательностей (временных рядов) с квазипериодическим изменением свойств. Рассматриваются содержательные задачи, типичные для таких приложений как электронная разведка, радиолокация, гидроакустика, телекоммуникация, геофизика, обработка речевых сигналов, медицинская и техническая диагностика и др. Апостериорный подход к решению этих задач, в отличие от традиционного – последовательного (on-line) – подхода, до настоящего времени остается слабо изученным.

Как известно, последовательный подход ориентирован на получение решения, оптимального лишь на текущий временной момент, в то время как апостериорный подход направлен на поиск решения, оптимального за весь промежуток времени наблюдения. Достоинство последовательного подхода состоит в том, что он позволяет конструировать быстрые (полиномиальные) алгоритмы, которые опираются на классические статистические методы проверки гипотез, оценивания и оптимальной фильтрации. При последовательном подходе к решению типовых задач проблемы комбинаторной оптимизации, как правило, не возникают. Очевидный недостаток этого подхода состоит в том, что в общем случае он не гарантирует отыскание оптимального решения задачи по совокупности всех накопленных данных. Иными словами, последовательный подход потенциально менее точен, чем апостериорный.

Напротив, апостериорный подход потенциально точнее, однако его применение сопряжено с решением задач комбинаторной оптимизации, к которым сводится поиск экстремума критерия качества решения (например, максимизация функции правдоподобия). Эти задачи возникают из-за необходимости выбора наилучшего решения из допустимой совокупности, мощность которой растет экспоненциально с увеличением числа членов последовательности. Анализ сложности этих комбинаторных

задач и построение полиномиальных алгоритмов с оценками для их решения – одна из ключевых проблем, решение которой необходимо для реализации апостериорного подхода. Вторая, не менее важная, проблема – изучение статистических свойств получаемых решений (алгоритмов); эта проблема в данной работе не затрагивается.

Ниже приведен список задач, для которых полиномиальные алгоритмы с оценками их точности ранее были неизвестны. Вместе с названием задачи указана временная сложность алгоритма решения экстремальной задачи, возникающей при реализации принципа максимального правдоподобия: (а) – в случае, когда число фрагментов известно и (б) – в случае, когда это число неизвестно. В записи временной сложности приняты обозначения: N – число членов в наблюдаемой последовательности, q – число членов во фрагменте и в эталонной последовательности, T_{\min} и T_{\max} – минимальный и максимальный интервал между двумя последовательными фрагментами, M – число фрагментов в последовательности, M_{\max} – максимальное число фрагментов в последовательности, K – мощность алфавита эталонных последовательностей, которые допустимы в качестве фрагментов анализируемой последовательности, L – число серий в последовательности, L_{\max} – максимальная размерность набора (слова) из эталонных последовательностей или максимальное число серий в последовательности, J – мощность словаря эталонных наборов; $\tilde{T} = T_{\max} - T_{\min} + 1$, $\tilde{N} = N - q + 1$.

Для всех задач из приведенного ниже списка, за исключением последней, обоснованы алгоритмы, гарантирующие отыскание точного решения экстремальной задачи и глобального экстремума функции правдоподобия. Для двух вариантов последней задачи обоснованы приближенные алгоритмы; вариант (а) этой задачи NP-труден; статус сложности варианта (б) пока не выяснен.

Список типовых задач

1. Обнаружение заданного повторяющегося фрагмента: а) $O(M\tilde{T}\tilde{N})$, б) $O(\tilde{T}\tilde{N})$.
2. Обнаружение заданного повторяющегося фрагмента по его обрывкам: а) $O[M(\tilde{T} + q^2)\tilde{N}]$, б) $O[(\tilde{T} + q^2)\tilde{N}]$.
3. Совместное обнаружение и идентификация фрагментов как элементов алфавита: а) $O[M(\tilde{T} + K)\tilde{N}]$, б) $O[(\tilde{T} + K)\tilde{N}]$.

4. Совместное обнаружение и идентификация фрагментов по их обрывкам: а) $O[M(\tilde{T} + Kq^2)\tilde{N}]$, б) $O[(\tilde{T} + Kq^2)\tilde{N}]$.

5. Распознавание последовательности, включающей повторяющийся эталонный фрагмент: а) $O(KM\tilde{T}\tilde{N})$, б) $O(K\tilde{T}\tilde{N})$.

6. Распознавание последовательности, включающей обрывки эталонной последовательности: а) $O[KM(\tilde{T} + q^2)\tilde{N}]$, б) $O[K(\tilde{T} + q^2)\tilde{N}]$.

7. Совместное обнаружение фрагментов в последовательности и ее разбиение на серии: а) $O(LM\tilde{T}\tilde{N})$, б) $O(L\tilde{T}\tilde{N})$.

8. Распознавание последовательности, включающей серии повторяющихся фрагментов: а) $O(JL_{\max}M\tilde{T}\tilde{N})$, б) $O(JL_{\max}\tilde{T}\tilde{N})$.

9. Обнаружение неизвестного повторяющегося фрагмента: а) $O(M^2\tilde{T}\tilde{N})$, б) $O(M_{\max}\tilde{T}\tilde{N})$.

Работа выполнена в рамках проектов № 94-01-00169, № 97-01-00866, № 00-01-00795, № 03-01-00036, поддержанных РФФИ.

**Максимально правдоподобное апостериорное
обнаружение и идентификация фрагментов числовой
последовательности по их обрывкам**

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

Рассматривается апостериорный (off-line) подход к решению задачи совместного обнаружения и идентификации квазипериодических фрагментов в числовой последовательности по их обрывкам. Получено решение задачи для случая, когда число искомых фрагментов неизвестно. Предполагается, что: 1) каждый искомый фрагмент числовой последовательности совпадает с элементом из заданного алфавита эталонных последовательностей, имеющих одинаковое заданное число членов; 2) для обработки потенциально доступен лишь обрывок (часть) от каждого искомого фрагмента; недоступные для обработки части этого фрагмента интерпретируются как потерянные данные; 3) номера членов последовательности, соответствующие началу искомого фрагмента и границам обрывков этого фрагмента, – детерминированные (не случайные) величины; границы обрывков изменяются от фрагмента к фрагменту, а искомые фрагменты встречаются в последовательности квазипериодически; 4) гауссовская некоррелированная помеха скрывает от наблюдения последовательность, включающую квазипериодические

обрывки эталонных последовательностей.

Для решения этой задачи до настоящего времени были неизвестны какие-либо полиномиальные алгоритмы апостериорного типа с оценками их точности. Существующие апостериорные полиномиальные алгоритмы с оценками ориентированы либо на случай, когда число искомых фрагментов известно, либо на случай, когда мощность алфавита эталонных последовательностей равна единице [1-3].

Содержательная задача состоит в следующем. Источник сообщений передает информацию о состоянии некоторого физического объекта через канал связи с помехами. В распоряжении источника сообщений имеется алфавит эталонных импульсов различной формы и одинаковой длительности. Форма импульса характеризует состояние объекта. Каждому состоянию соответствует единственный эталонный импульс из алфавита. Источник сообщений посылает эталонные импульсы, соответствующие текущему состоянию объекта. На приемную сторону вместо последовательности эталонных импульсов поступает и накапливается последовательность их фрагментов (обрывков), т.е. импульсов, у которых отсутствуют начальные и / или конечные участки. Эти участки недоступны для наблюдения из-за помех. Границы потенциально доступных для наблюдения участков – обрывков импульсов – неизвестны и изменяются от импульса к импульсу; импульсы повторяются квазипериодически; общее число переданных импульсов неизвестно. Предполагается, что принятая (наблюдаемая) последовательность обрывков импульсов искажена аддитивным шумом. Требуется обнаружить эталонные импульсы в последовательности и идентифицировать их как элементы алфавита.

Формально, пусть компоненты вектора $X \in \mathfrak{R}^N$ образованы по правилу: $x_n = \sum_{m=1}^M u_{n-n_m}(m)$, $n = \overline{0, N-1}$, где $u_n(m) = 0$, при $n \neq \overline{0, q-1}$ (q – натуральное число). Положим $U_m = (u_0(m), \dots, u_{q-1}(m))$ и допустим, что $U_m \in A$, где A – конечный алфавит. Вектор $U \in A$ будем называть эталонным вектором. Положим $\eta = (n_1, \dots, n_M)$, $w = (U_1, \dots, U_M)$ и допустим, что $\eta \in \Omega_M = \{(n_1, \dots, n_M) : 0 \leq n_1 \leq T_{\max} - q; q \leq T_{\min} \leq n_m - n_{m-1} \leq T_{\max}, m = \overline{2, M}; 0 \leq N - T_{\max} \leq n_M \leq N - q\}$, $M \in [M_{\min}, M_{\max}]$, где $M_{\min} = \lfloor (N + q - 1) / T_{\max} \rfloor$ и $M_{\max} = \lfloor (N - q) / T_{\min} \rfloor + 1$, см. [1].

В определении множества Ω_M пара ограничений на n_1 и n_M – краевые условия, а третье ограничение – условие квазипериодичности. Компоненты вектора X образуют квазипериодическую последовательность, порожденную набором W эталонных векторов из алфавита. Элементы набора η интерпретируются как моменты времени начала импульсов в последовательности.

Фрагмент $(u_{q^-}, \dots, u_{q^+})$ последовательности компонент эталонного вектора U , где $(q^-, q^+) \in Q = \{(q^-, q^+) : 0 \leq q^- \leq q^+ \leq q-1\}$, называется ее обрывком, а q^- и q^+ – левой и правой границами обрывка 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} образуют последовательность $\tilde{x}_n = \sum_{m=1}^M \tilde{u}_{n-n_m}(q_m^-, q_m^+, u_{n-n_m}(m))$, $n = 0, \dots, N-1$, где $\tilde{u}_j(\cdot) = 0$, если $j \neq 0, \dots, q-1$. Положим

$$\xi = ((q_1^-, q_1^+), \dots, (q_M^-, q_M^+)) \text{ и допустим, что } \xi \in Q^M.$$

Пусть наблюдаемый случайный вектор $Y = \tilde{X}(\eta, \xi, w) + E$, где $E \in \Phi_{0, \sigma^2 I}$. Задача совместного обнаружения и идентификации состоит в том, чтобы по вектору Y найти пару наборов η и w , включающих неизвестное число M компонент. Параметры задачи $N, T_{\min}, T_{\max}, q, \sigma$ и алфавит A эталонных векторов предполагаются известными. Набор ξ рассматривается как неизвестный мешающий параметр.

Установлено, что сущность рассматриваемой задачи состоит в проверке совокупности простых гипотез о среднем \tilde{X} случайного гауссовского вектора Y ; мощность этой совокупности растет экспоненциально с увеличением числа членов последовательности N и

числа M . Показано, что отыскание максимально правдоподобной гипотезы сводится к решению экстремальной задачи

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

где $(\eta, \xi, w) \in \bigcup_{M=M_{\min}}^{M_{\max}} \Omega_M \times Q^M \times A^M$.

Обоснован полиномиальный алгоритм, гарантирующий точное решение этой задачи и максимально правдоподобное совместное обнаружение и идентификацию.

Работа выполнена в рамках проекта № 03-01-00036, поддержанного РФФИ.

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. Апостериорное обнаружение квазипериодически повторяющегося фрагмента в числовой последовательности в условиях шума и потери данных // Сиб. журн. индустр. математики. 2003. Т.6, №2(14). С. 46-63.
3. Кельманов А.В., Хамидуллин С.А. Совместное апостериорное обнаружение и идентификация заданного числа квазипериодических фрагментов в последовательности по их обрывкам // Сиб. журн. индустр. математики. 2005. Т.8, № 2(22). С.83-102.

О построении комитета двумерной системы неоднородных линейных неравенств

К.С. Кобылкин

(Екатеринбург)

Обобщением понятия решения системы линейных неравенств

$$(c_j, x) > b_j, c_j, x \in \mathbb{R}^n, b_j \in \mathbb{R}, j = 1, \dots, m$$

на случай несовместных систем является *комитет* [1] – набор точек из \mathbb{R}^n такой, что каждому неравенству системы удовлетворяет более половины его членов. Комитет используется на практике [2] как аналог разделяющей функции в задачах обучения распознаванию образов, для случая, когда выпуклые оболочки выборок из двух классов не делимы гиперплоскостью. Один из методов построения комитета в многомерном пространстве [1] состоит в нахождении комитета некоторой плоской

системы однородных линейных неравенств с наименьшим числом членов, называемого *минимальным* комитетом. Работа посвящена задаче построения комитета из трех элементов несовместной двумерной системы неоднородных линейных неравенств, которая непосредственно связана с этой задачей для трехмерных систем однородных линейных неравенств. Исследование таких систем является основой для новых методов нахождения комитета с меньшим, чем в упомянутом выше методе, числом членов, что дает более простую и практически полезную комитетную разделяющую функцию.

Метод построения комитета из трех членов

Рассмотрим несовместную двумерную систему линейных неравенств

$$(c_j, h) > b_j, \quad c_j, h \in \mathbb{R}^2, \quad b_j \in \mathbb{R}, \quad j = 1, \dots, m, \quad (1)$$

для которой существует комитет.

Определение. Назовем МСП T системы (1) *отмеченной*, если она содержит такую пару неравенств, называемую *определяющей*, что любая МСП системы (1), содержащая эту пару, совпадает с T , причем любое решение определяющей пары неравенств, достаточно близкое к элементу, обращаемому неравенства этой пары в равенства, удовлетворяет подсистеме T .

Оказывается, если K – комитет системы (1) с условием, что каждый его член является решением некоторой МСП системы (1), то любая отмеченная МСП этой системы обладает решением, входящим в K с положительной кратностью. Приведем процедуру нахождения отмеченной МСП. Пусть $D = \{D_j\}_{j=1}^m$ – система полуплоскостей, каждая из которых является множеством решений соответствующего неравенства системы (1).

Процедура. Рассмотрим некоторую полуплоскость $D^{(0)} \in D$ и точку $h^{(0)}$ на ее границе $l^{(0)}$, совпадающую с одной из двух крайних точек пересечения $l^{(0)}$ с граничными прямыми других полуплоскостей системы D . Возьмем на прямой $l^{(0)}$ луч r_0 с вершиной в точке $h^{(0)}$, содержащий обе крайних точки. Рассмотрим следующий процесс. Пересечение

$$\bigcap \{D \cap l^{(0)} : D \in D, D \cap r_0 - \text{луч}\}$$

совпадает с некоторым лучом $D' \cap l^{(0)}$, $D' \in D$, а пересечение

$$\bigcap \{D \cap D^{(0)} : D \in D, D \cap l^{(0)} = D' \cap l^{(0)}\}$$

– с некоторым конусом $D^{(1)} \cap D^{(0)}$, $D^{(1)} \in D$, вершину которого обозначим через $h^{(1)}$; $h^{(1)} = l^{(1)} \cap l^{(0)}$, где $l^{(1)}$ – граница полуплоскости $D^{(1)}$. Пусть $r_1 = D^{(0)} \cap l^{(1)}$. Аналогично, пересечение

$$\bigcap \{D \cap l^{(1)} : D \in D, D \cap r_1 - \text{луч}\}$$

совпадает с некоторым лучом $D'' \cap l^{(1)}$, $D'' \in D$, а пересечение

$$\bigcap \{D \cap D^{(1)} : D \in D, D \cap l^{(1)} = D'' \cap l^{(1)}\}$$

– с некоторым конусом $D^{(2)} \cap D^{(1)}$, $D^{(2)} \in D$. Пусть $h^{(2)}$ – вершина этого конуса; $h^{(2)} = l^{(2)} \cap l^{(1)}$, где $l^{(2)}$ – граница полуплоскости $D^{(2)}$. Если $h^{(1)} = h^{(2)}$, то процедура заканчивается. В случае, когда $h^{(1)} \neq h^{(2)}$, проведем аналогичные построения для прямой $l^{(2)}$ и луча $r_2 = D^{(1)} \cap l^{(2)}$. Будем продолжать данный процесс до тех пор, пока для некоторого k_0 , $k_0 \geq 2$, не будет выполнено равенство $h^{(k_0-1)} = h^{(k_0)}$.

Выберем точку $\bar{h} \in D^{(k_0-1)} \cap D^{(k_0)}$, лежащую в столь малой окрестности точки $h^{(k_0)}$, что $\bar{h} \in \bigcap \{D \in D : h^{(k_0)} \in D\}$. Обозначим через S подсистему, составленную из двух неравенств системы (1), множествами решений которых являются полуплоскости $D^{(k_0-1)}$ и $D^{(k_0)}$. Рассмотрим неравенство системы (1), образующее вместе с двумя неравенствами из S совместную подсистему, и составим из всех таких неравенств подсистему, которую обозначим через T . Процедура завершена.

При этом, подсистема $T = T(D^{(0)}, r_0)$ совпадает с некоторой отмеченной МСП системы (1), два неравенства из S составляют определяющую пару в T , а вектор \bar{h} является решением подсистемы T . Применяя процедуру с определенными параметрами $D^{(0)}$ и r_0 , можно найти любую из отмеченных МСП системы (1). В случае совместной системы ранга 2 применение процедуры к произвольной полуплоскости системы D и некоторому лучу на ее границе дает решение \bar{h} этой

системы.

Алгоритм построения комитета из трех членов. Пусть $D^{(0)} \in D$ – произвольная полуплоскость. Рассмотрим отмеченную МСП T_1 системы (1), ее решение \bar{h}_1 и определяющую пару неравенств S_1 , входящую в T_1 , которые найдены при применении процедуры, описанной выше, к полуплоскости $D^{(0)}$ и произвольному лучу на ее границе. Пусть E и E' – полуплоскости, являющиеся множествами решений двух неравенств, составляющих подсистему S_1 . Положим $D^{(0)} := E$. Применив процедуру к полуплоскости $D^{(0)}$ и лучу на ее границе $l^{(0)}$, противоположно направленному с лучом $E' \cap l^{(0)}$, найдем некоторую отмеченную МСП T_2 системы (1) и ее решение \bar{h}_2 . Положим $D^{(0)} := E'$. Рассмотрим отмеченную МСП T_3 и ее решение \bar{h}_3 , которые найдены при применении процедуры к полуплоскости $D^{(0)}$ и лучу на ее границе $l^{(0)}$, противоположно направленному с лучом $E \cap l^{(0)}$.

Пусть $\bar{K} = \{\bar{h}_1, \bar{h}_2, \bar{h}_3\}$. Оказывается, система (1) имеет комитет из трех членов тогда и только тогда, когда \bar{K} является ее комитетом. Справедлива

Теорема. Для того, чтобы система (1) имела минимальный комитет из трех членов необходимо и достаточно, чтобы любая ее подсистема из 5 неравенств включала в себя совместную подсистему из 4 неравенств.

Литература

1. Мазуров Вл.Д. Метод комитетов в задачах оптимизации и классификации // Наука. М., 1990. 248 с.
2. Казанцев В.С. Задачи классификации и их программное обеспечение // Наука. М., 1990. 136 с.

Об одной нетрадиционной задаче проверки сложных гипотез

Д.А. Кольцов, М.Л. Сердобольская
(Москва)

Рассматриваемая задача проверки сложных гипотез, характерная для проблемы эмпирического восстановления возможности, была предложена

профессором Ю. П. Пытьевым. Особенностью этой задачи является то, что последовательности элементов выборки могут отвечать любые комбинации простых гипотез в составе одной сложной, контролирующей выборку, причем отсутствует стохастическая закономерность появления простых гипотез в последовательности распределений наблюдений.

Пусть $\mathbf{H}^q = \{\mathbf{H}_1^q, \dots, \mathbf{H}_{m_q}^q\}$, $q = 1, 2, \dots, Q$, – класс сложных гипотез о распределении некоторой случайной величины. Мы рассматриваем конечные дискретные распределения и предполагаем, что каждая реализация случайной величины принадлежит конечному множеству элементарных исходов $\Omega = \{\omega_1, \omega_2, \dots, \omega_S\}$; кроме того, далее мы рассматриваем случай $Q=2$, при этом $\mathbf{H}^1 = \mathbf{H}$ (гипотеза), $\mathbf{H}^2 = \mathbf{K}$ (альтернатива)¹. Предположим, что решение о том, какая из сложных гипотез верна, принимается на основании реализации N -мерного случайного вектора $\xi = \langle \xi_1, \xi_2, \dots, \xi_N \rangle$, координаты которого независимы. При этом мы считаем, что распределение каждой координаты контролируется какой-либо простой гипотезой $\mathbf{H}_i^q \in \mathbf{H}^q$, $i = 1, 2, \dots, m_q$.

Отметим, что в традиционных постановках задачи проверки сложных гипотез либо все наблюдения контролируются одним и тем же распределением, отвечающим неизвестной простой гипотезе в составе сложной, либо предполагается, что на множестве гипотез задана некое распределение вероятностей (байесовская постановка) [1].

Предлагается следующий алгоритм решения задачи.

Пусть $\Pr_{H_i}(\cdot)$, $\Pr_{K_j}(\cdot)$, $i(j) = 1, \dots, m_H(m_K)$, – распределения вероятностей, отвечающие простым гипотезам \mathbf{H}_i и \mathbf{K}_j в составе сложных \mathbf{H} и \mathbf{K} , соответственно.

Шаг 1. Априори (т.е. независимо от полученной в эксперименте реализации случайного вектора ξ) решается следующая минимаксная задача:

$$L^* = \min_{\pi} \max \left(\max_{\gamma^K} L_H(\gamma^K; \pi), \max_{\gamma^H} L_H(\gamma^H; \pi) \right), \quad (1)$$

$$\text{где } L_H(\gamma^K; \pi) = \sum_{j=1}^{m_K} l_j^H \gamma_j^K \sum_{s=1}^S \Pr_{K_j}(\omega_s) \pi(\omega_s), \quad (2)$$

$$L_K(\gamma^H; \pi) = \sum_{i=1}^{m_H} l_i^K \gamma_i^H \sum_{s=1}^S \Pr_{H_i}(\omega_s) (1 - \pi(\omega_s)), \quad (3)$$

¹ Решение для большего числа сложных гипотез не содержит принципиальных трудностей и получается тривиальным обобщением.

– функции риска; l_j^H (l_i^K) – значения потерь, сопровождающих ошибочное решение о том, что реализация случайной величины ξ_n признана свидетельствующей в пользу **H** (в пользу **K**) вопреки тому, что ξ_n распределена в соответствии с j -ой простой альтернативой (i -ой простой гипотезой); множитель γ_j^K (γ_i^H) может быть интерпретирован как «вес» простой альтернативы **K_j** (простой гипотезы **H_i**) в распределении случайного вектора ξ , $i(j) = 1, 2, \dots, m_H$ (m_K), а каждая из координат вектора $\pi^* = \langle \pi_1^*, \pi_2^*, \dots, \pi_S^* \rangle$, доставляющего экстремум в (1), интерпретируется как вероятность того, что значение ω_s будет признано свидетельствующим в пользу **H** (с вероятностью $1 - \pi_s^*$ это значение будет признано свидетельствующим в пользу **K**), $s = 1, 2, \dots, S$. Таким образом, вектор π^* определяет рандомизированную процедуру решения;

Шаг 2. По найденному вектору π^* и полученной реализации случайного вектора ξ определяется количество $N(H)$ значений ω_{s_n} , $n=1, 2, \dots, N$, признанных свидетельствующими в пользу **H**, окончательное решение принимается по значению доли (частоты) $v(H) = N(H) / N$;

Шаг 3. Если частота велика, $v(H) > T$, то принимается гипотеза **H**, в противном случае – альтернатива **K**; “критическое” значение T определим далее.

Предлагаемый алгоритм позволяет построить статистический критерий, обладающий свойством состоятельности, и связать вероятности ошибочных решений с количеством наблюдений. Введем случайные величины

$$\mathcal{G}_n = \begin{cases} 1, & \text{если } \xi_n \text{ отнесена к } \mathbf{H} \text{ на шаге 1 (см. выше)} \\ 0, & \text{если } \xi_n \text{ отнесена к } \mathbf{K} \text{ на шаге 1 (см. выше)} \end{cases}, n = 1, 2, \dots, N,$$

$$\text{тогда } v(H) = \frac{1}{N} \sum_{n=1}^N \mathcal{G}_n. \text{ Распределение } \xi_n, \text{ отвечающее } \mathbf{H}_i \text{ (} \mathbf{K}_j \text{),}$$

и рандомизированная процедура, задаваемая вектором π^* , полностью определяют распределение \mathcal{G}_n , $n=1, 2, \dots, N$, которое мы будем обозначать

$$\Pr_{H_i, \pi^*}(\Pr_{K_j, \pi^*}), \quad i = 1, 2, \dots, m_H, \quad j = 1, 2, \dots, m_K, \text{ и, следовательно,}$$

распределение $v(H)$.

Теорема. Пусть в (2), (3) $l_j^H = l_i^K = 1$ для всех $i = 1, 2, \dots, m_H, j = 1, 2, \dots, m_K$,

$$\max_{1 \leq j \leq m_K} \sum_{s=1}^S \pi^*(\omega_s) \Pr_{K_j}(\omega_s) \equiv \bar{E}_K < \underline{E}_H \equiv \min_{1 \leq i \leq m_H} \sum_{s=1}^S \pi^*(\omega_s) \Pr_{H_i}(\omega_s).$$

Тогда для любых $\gamma_i^H, \gamma_j^K \in [0,1]$, $\sum_{i=1}^{m_H} \gamma_i^H = \sum_{j=1}^{m_K} \gamma_j^K = 1$,

$$\sum_{i=1}^{m_H} \gamma_i^H \Pr_{H_i, \pi^*} (v(H) < T) \leq \frac{\max_{1 \leq i \leq m_H} D_{H_i}^*}{N(\underline{E}_H - T)},$$

$$\sum_{j=1}^{m_K} \gamma_j^K \Pr_{K_j, \pi^*} (v(H) > T) \leq \frac{\max_{1 \leq j \leq m_K} D_{K_j}^*}{N(T - \overline{E}_K)},$$

где $T \in (\overline{E}_K, \underline{E}_H)$, $D_{H_i}^* (D_{K_j}^*)$ – дисперсия случайной величины \mathcal{G}_n при условии, что она распределена в соответствии с $\Pr_{H_i, \pi^*} (\Pr_{K_j, \pi^*})$.

Рассмотренный алгоритм не использует апостериорной (т.е. содержащейся в измерении ξ) информации о значениях $\gamma_i^H (\gamma_j^K)$ в отличие от предложенного в работе [2].

Авторы благодарят профессора Ю.П. Пытьева за постановку интересной задачи, ценные научные рекомендации и плодотворные обсуждения.

Литература.

1. Боровков А.А. Математическая статистика // Наука. Москва, 1984.
2. Пытьев Ю.П. Вероятностные и возможностные оптимальные решения
I. Вероятностные решения. // Интеллектуальные системы. 2006. Том 9.
№ 1–4. (в печати).

Итерационные методы парно-сепарабельной оптимизации на основе древовидного динамического программирования в задачах анализа многомерных

данных

А.В. Копылов

(Тула)

Существует достаточно широкий класс задач обработки изображений и многомерных массивов данных, которые могут быть сформулированы математически как оптимизационные задачи специального вида на множестве переменных связанных с элементами дискретного раstra.

В этот класс обычно входят такие задачи анализа данных, которые могут быть представлены как задачи преобразования исходного массива $\mathbf{Y} = (y_t, t \in T)$, $y \in \mathbf{Y}$, в другую функцию $\mathbf{X} = (x_t, t \in T)$, которая

должна быть определена на том же множестве элементов массива $t \in T$ и принимать значения $x \in X$ из множества, специфичного для каждой частной задачи. Поскольку результатом анализа данных является искомый вторичный массив $X = (x_t, t \in T)$, то он должен играть роль аргумента целевой функции $J(X|Y)$, оценивающей несоответствие между каждой допустимой версией результата X и исходным массивом данных Y . Выбор множества значений отдельных переменных $x_t \in X$ полностью определяет область определения целевой функции.

Такая задача может быть поставлена формально как задача минимизации действительной целевой функции следующего вида

$$J(X|Y) = \sum_{t \in T} \psi_t(x_t | Y) + \sum_{(t', t'') \in G} \gamma_{t', t''}(x_{t'}, x_{t''}) \quad (1)$$

Здесь $G \subseteq T \times T$ граф непосредственного соседства элементов дискретного раstra, имеющий в случае изображений, форму прямоугольной решетки. Функции ψ_t играют роль штрафа на различие значений исходного массива данных функции Y и результирующей функции X и обычно выбираются квадратичными. Каждая функция связи $\gamma_{t', t''}$ налагает штраф на негладкость результата обработки на соответствующем ребре (t', t'') графа соседства G .

Специфика данной задачи заключается в структуре целевой функции, которая является суммой элементарных целевых функций, каждая из которых зависит лишь от пары соседних переменных. Такие целевые функции мы называем парно-сепарабельными.

Если граф G соседства переменных представляет собой цепь, для решения данной задачи существует эффективная в вычислительном плане классическая процедура динамического программирования [1], имеющая линейную вычислительную сложность относительно количества целевых переменных. Одним из центральных положений оптимизационного подхода к построению алгоритмов анализа массивов данных является установленный в работе [2] факт, что если граф смежности переменных G не имеет циклов, то есть является деревом, то существует естественное обобщение классической процедуры динамического программирования с ничуть не худшими вычислительными свойствами, чем в случае цепи.

К сожалению, поиск алгоритма оптимизации для сепарабельных функций с графами смежности переменных в виде прямоугольной решетки неизбежно ведет к вычислительным трудностям. Одним из

способов преодоления этого обстоятельства является древовидная аппроксимация графа соседства [2, 3].

Тем не менее, такая аппроксимация, хотя и приводит к быстрым алгоритмам анализа изображений и данных большей размерности, все же не позволяет найти точный минимум критерия (1). В данной работе предлагается другой способ использования преимуществ древовидного динамического программирования для построения итерационной процедуры оптимизации критерия подобного вида.

Основная идея данного метода состоит в разбиении исходного графа соседства в виде решетки на два или большее число поддеревьев, например, так, как это показано на рис. 1. Тогда, зафиксировав значения целевых переменных в одном поддереве, возможно провести оптимизацию по другому поддереву при помощи процедуры древовидного динамического программирования, и получить новые значения переменных в этом дереве. Далее процесс повторяется для другого поддерева, пока не будет достигнута требуемая точность.




Рис. 1. Примеры разбиения графа в виде прямоугольной решетки на два поддерева.

В случае если функции Ψ_t и $\gamma_{t',t''}$ выпуклые, то легко показать, что такой процесс сходится, находя при этом значение глобального минимума исходного критерия (1).

На рис. 2 показаны результаты сглаживания простейшего изображения $\mathbf{Y}=(y_{t_1 t_2}, t_1=1, \dots, N_1, t_2=1, \dots, N_2)$ (рис. 2, а), полученные путем решения задачи минимизации квадратичной целевой функции вида (1) при $N_1 = N_2 = 100$ с узловыми функциями $\Psi_{t_1 t_2}(x_{t_1 t_2}) = (x_{t_1 t_2} - y_{t_1 t_2})^2$ при одинаковых функциях связи для вертикальной $\gamma'(x_{t_1-1, t_2}, x_{t_1 t_2}) = u(x_{t_1-1, t_2} - x_{t_1 t_2})^2$ и горизонтальной смежности

$\gamma''(x_{t_1, t_2-1}, x_{t_1 t_2}) = u(x_{t_1, t_2-1}, x_{t_1 t_2})^2$. Решение на рис. 2,б для $N_1 N_2 = 10000$ непрерывных переменных $x_{t_1 t_2} \in \mathbf{R}$ найдено с помощью итерационного решения 10000 линейных уравнений с 10000 неизвестными, а решение задачи на рис. 2,в – применением итерационной процедуры динамического программирования с разбиением исходного графа на два поддерева, показанным на рис. 1,б.




Рис. 2. Простейшее изображение и результаты его сглаживания двумя разными методами.

Литература

1. Bellman R. Dynamic Programming. Princeton University Press, Princeton, N.J., 1957.
2. Muchnik I., Mottl V. Bellman Functions on Trees for Segmentation, Generalized Smoothing, Matching and Multi-Alignment in Massive Data Sets. DIMACS Technical Report 98-15, April 1998. Center for Discrete Mathematics and Theoretical Computer Science. Rutgers University, the State University of New Jersey.
3. Mottl V., Kopylov A., Blinov A., Kostin A. Optimization techniques on pixel neighborhood graphs for image processing. // Graph-Based Representations in Pattern Recognition. Computing, Supplement 12. Springer-Verlag/Wien, 1998, pp. 135-145.

Критерии и алгоритмы оценивания нестационарной регрессии в анализе временных рядов

А.В. Копылов, О.А. Красоткина, В.В. Моттль
(Тула)

В отличие от классической постановки задачи восстановления некоторой закономерности в генеральной совокупности с неизменными свойствами, предположение о зависимости свойств генеральной совокупности от времени неизбежно приводит к необходимости анализа последовательности выборок в некоторые моменты времени. Если целевая характеристика объектов в искомой закономерности выражается номинальной переменной, то говорят о задаче обучения распознаванию

образов, если это действительная переменная, то такую задачу называют задачей оценивания регрессионной зависимости. Последовательность результатов измерений тех или иных характеристик объектов в составе соответствующих выборок мы называем в данной работе потоком данных.

В частности, многие задачи анализа потоков данных сводятся к оцениванию линейной нестационарной модели, адекватной, например, задачам сглаживания и нестационарного авторегрессионного анализа сигналов, спектральная форма представления которого эквивалентна спектрально-временному анализу.

Предполагается, что подлежащий анализу векторный сигнал $Y = (y_t = (y_t^o, \mathbf{y}_t), t = 1, \dots, N)$ состоит из двух частей – векторной последовательности $\mathbf{y}_t \in \mathbf{R}^n$ и числовой последовательности $y_t^o \in \mathbf{R}$. Основное модельное предположение состоит в том, что числовая компонента y_t^o в каждой точке наблюдения получена как зашумленная линейная функция векторной компоненты \mathbf{y}_t

$$y_t^o = \mathbf{x}_t^T \mathbf{y}_t + \varepsilon_t, \quad (1)$$

определяемая последовательностью неизвестных векторных коэффициентов регрессии $\mathbf{x}_t \in \mathbf{R}^n$. Задача заключается в оценивании последовательности коэффициентов нестационарной линейной модели $X = (\mathbf{x}_t, t = 1, \dots, N)$ в предположении, что они изменяются в основном достаточно медленно. Шум наблюдения ε_t рассматривается как белый шум с неизвестной интенсивностью.

Простейшим вариантом подобной задачи является задача сглаживания скалярного сигнала. Будем рассматривать исходный скалярный сигнал как сумму $y_t^o = x_t + \varepsilon_t$ скрытого сигнала x_t , который необходимо восстановить, и аддитивного шума ε_t с нулевым средним. Целью обработки исходного сигнала y_t^o является подавление шума, т.е. восстановление скрытого сигнала x_t .

От искомой последовательности значений $X = (x_t, t = 1, \dots, N)$ естественно потребовать, чтобы квадрат остатка аппроксимации сигнала был как можно меньше в каждой точке. Априорные предположения о гладкости искомого сигнала могут быть выражены в форме штрафа на его первую и вторую разность [1].

В случае непрерывного времени такая постановка приводит к следующей вариационной задаче:

$$\int_0^T [y^0(t) - x(t)]^2 dt + \lambda \int_0^T \left[\frac{d}{dt} x(t)\right]^2 dt + \mu \int_0^T \left[\frac{d^2}{dt^2} x(t)\right]^2 dt \rightarrow \min \quad (2)$$

Как описано в [2], при $\lambda = 0$ сигнал $x(t)$, доставляющий минимум данному функционалу, представляет собой кубический сплайн, т.е. множество полиномов третьей степени, соединенных в некоторых точках на оси аргумента t . Эксперименты показывают, это свойство справедливо и для исходной задачи (1) оценивания нестационарной регрессии в дискретном виде. Целевая функция при этом приобретает несколько более сложный вид:

$$\begin{aligned} \sum_{t=1}^N [y^0(t) - \sum_{i=1}^n y^{(i)}(t)x^{(i)}(t)]^2 + \sum_{i=1}^n \lambda^{(i)} \sum_{t=2}^N (x_t^{(i)} - x_{t-1}^{(i)})^2 \\ + \sum_{i=1}^n \mu^{(i)} \sum_{t=2}^{N-1} (x_{t+1}^{(i)} - 2x_t^{(i)} + x_{t-1}^{(i)})^2 \rightarrow \min, \quad (3) \end{aligned}$$

Здесь $y^{(i)}(t)$ - известные регрессоры. Решение задачи может быть найдено как решение системы линейных уравнений алгебраических уравнений с блочно-пятидиагональной матрицей, например, методом прогонки. В [3] показано, что метод прогонки эквивалентен квадратичному динамическому программированию и фильтру-интерполятору Калмана-Бьюси.

Однако для многих практических задач квадратичный штраф на первую и вторую разность последовательности коэффициентов нестационарной линейной модели $X = (\mathbf{x}_t, t = 1, \dots, N)$ приводит к сглаживанию существенных особенностей искомым коэффициентов. В этом случае априорную информацию о динамике скрытых коэффициентов регрессии удобнее выражать в виде штрафа на модуль их первой и второй разности, что приводит к критерию следующего вида

$$\begin{aligned} \sum_{t=1}^N [y^0(t) - \sum_{i=1}^n y^{(i)}(t)x^{(i)}(t)]^2 + \sum_{i=1}^n \lambda^{(i)} \sum_{t=2}^N |x_t^{(i)} - x_{t-1}^{(i)}| + \\ + \sum_{i=1}^n \mu^{(i)} \sum_{t=2}^{N-1} |x_{t+1}^{(i)} - 2x_t^{(i)} + x_{t-1}^{(i)}| \rightarrow \min. \quad (4) \end{aligned}$$

Подобная задача может быть сведена к задаче квадратичного программирования за счет добавления служебных переменных и введения ограничений на них. Получающаяся при этом целевая функция, есть сумма функций не более чем одной векторной переменной, связанной с очередным моментом времени, а ограничения (типа неравенств) наложены

лишь на не более чем тройки смежных переменных. Такие задачи оптимизации мы называем сепарабельными задачами. Для задач оптимизации такого типа разработана специальная процедура, на основе принципа динамического программирования, названная ленточно-сепарабельным квадратичным программированием.

Модельные эксперименты показывают, что оптимальным решением для критерия (4) при $\mu^{(i)} = 0$ является кусочно-постоянная последовательность коэффициентов X нестационарной модели т.е. сплайн нулевого порядка (рис. 1, б), при $\lambda^{(i)} = 0$ - кусочно-линейная, или сплайн первого порядка (рис. 1, в), что позволяет учитывать априорную информацию различного характера, в соответствии с конкретной решаемой задачей.




Рис. 1. Результаты оценивания векторных коэффициентов нестационарной регрессии: а) – исходная последовательность коэффициентов, подлежащая восстановлению; б) – оценка, согласно критерию (4), при штрафе только на первую разность; в) - оценка, согласно критерию (4), при штрафе только на вторую разность.

Литература

1. Krasotkina O. V., Mottl V. V., and Kopylov A. V. Algorithms of Estimation of Nonstationary Regression in Signal Analysis. Pattern Recognition and Image Analysis, Vol. 13, No. 1, 2003, pp. 127-131.
2. B. Efron, R.J. Tibshirani. An Introduction to the Bootstrap. Chapman & Hall, International Thomson Publishing. 1994.
3. Костин А.А., Красоткина О.В., Марков М.Р., Моттль В.В., Мучник И.Б. Алгоритмы динамического программирования для анализа нестационарных сигналов. Журнал вычислительной математики и математической физики, 2004, том 44, № 1, С. 70-86.

Определение типа фазовых траекторий динамических систем на основе оптимальных тупиковых нечетких тестов и синдромов

И.В. Котельников

(Нижний Новгород)

Работа относится к начальному этапу решения большой и сложной задачи полного качественного исследования поведения конкретных динамических систем порядка $n \geq 3$, заданных системой обыкновенных дифференциальных уравнений, с применением методов распознавания образов [1]. Задачи этого класса очень сложны и за редким исключением допускают полное исследование динамических систем хорошо разработанными традиционными методами, успешно применяемыми для систем порядка $n \leq 2$ [2,3]. Исследование базируется на изучении поведения в фазовом пространстве $\{x_1, x_2, \dots, x_n\}$ фазовых траекторий – кривых, соответствующих решению дифференциальных уравнений при заданных начальных условиях в последовательные моменты времени t_1, t_2, \dots и представляющих собой последовательность точек с координатами (x_1, x_2, \dots, x_n) . Фазовые траектории в таком виде нетрудно получить, например, с помощью системы MATLAB в виде файла с информацией

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

где X^i – точка фазовой траектории, соответствующая i -ому моменту времени, измеряемому с постоянным временным шагом.

Рассматриваются фазовые траектории следующих 4 типов:

1. Фазовая траектория с течением времени уходит за пределы исследуемого ограниченного фазового пространства, или, условно, при $t \rightarrow \infty$ уходит в ∞ .
2. При увеличении времени фазовая траектория стремится к точке $(x_1, x_2, \dots, x_n)^*$, представляющей собой устойчивое состояние равновесия динамической системы.
3. Внутри рассматриваемого ограниченного интервала времени при увеличении t фазовая траектория с возрастающей точностью приближается к некоторому замкнутому предельному циклу возможно очень сложной формы, соответствующему устойчивому периодическому движению рассматриваемой динамической системы.
4. Фазовая траектория относится к типу так называемого странного аттрактора, т.е. в пределах рассматриваемых отрезков времени

никогда не выходит за пределы некоторой ограниченной области фазового пространства, а внутри нее образует стохастические или хаотические движения. Стремления к какому-либо замкнутому предельному циклу не наблюдается. В силу ограниченности области фазового пространства с указанным типом движений такие движения динамической системы классифицируются как устойчивые, или, как еще говорят, устойчивые по Пуассону.

Цель данной работы – определение типа фазовой траектории (1) методами распознавания образов.

Определение первых двух типов траекторий не требует такого подхода. Тип траектории может быть установлен непосредственно из (1). Первому типу будут соответствовать траектории, у которых в (1) присутствует точка, хотя бы по одной из координат выходящая за пределы рассматриваемого ограниченного фазового пространства. Второму типу в (1) будет соответствовать при заданной точности вычислений целый ряд тождественных конечных точек траектории, соответствующих значению $(x_1, x_2, \dots, x_n)^*$, которое с заданной точностью вычислений и принимается за устойчивое состояние равновесия.

Методы распознавания образов применяются к определению типов 3 и 4 фазовых траекторий.

Основная идея определения типа траекторий состоит в построении в фазовом пространстве синдрома – прямоугольного параллелепипеда размерности $k \leq n$ с измерениями $\{a_\nu \leq x_\nu \leq b_\nu, \nu = \overline{1, k}\}$, через который многократно проходит фазовая траектория. В общем случае внутри синдрома могут оказаться целые группы последовательных точек траектории. Из них нас будут интересовать только первые точки таких последовательностей, соответствующие моментам вхождения траектории в синдром. Назовем для определенности такие точки головными точками последовательностей, или для краткости просто головными. Упорядочим головные точки в синдроме в порядке возрастания их номеров i и определим значения D_i разности номеров точек для каждой пары соседних точек. Поскольку решение уравнений получено при фиксированном временном шаге интегрирования, номера точек будут соответствовать числу пройденных шагов и, следовательно, пропорциональны времени, которому соответствует каждая точка, а разности номеров D_i будут пропорциональны временным интервалам между последовательными вхождениями траектории в синдром. Траекториям типа 3 будут соответствовать периодические вхождения траектории в синдром и периодический характер последовательности

значений D_i , чего не будет наблюдаться для траекторий типа 4, что и определяет признак идентификации типа траекторий. Поскольку последовательности D_i представлены целыми числами, их периодичность или аperiodичность легко может быть определена как визуально, так и программным способом.

К рассматриваемому синдрому предъявляется единственное требование. Он должен содержать достаточно большое число m_h головных точек, для того, чтобы отразить достаточно полно периодичность или аperiodичность движения траекторий.

Для поиска синдрома применяется алгоритм построения синдромальных решающих правил на основе оптимальных тупиковых нечетких тестов и синдромов [4]. Для достижения рассмотренных выше целей алгоритм несколько изменяется. Вместо применяемой в алгоритме процедуры многопараметрического упорядочения синдромов используется процедура упорядочения по единственному параметру m_h с предпочтением для больших значений. Разделим выборку (1) на ряд, например 2, последовательных временных интервалов – классов. Построим для выделенных классов синдромальное решающее правило [4]. Отберем из полученного решающего правила синдром с максимальным числом m_h головных точек. На множестве головных точек этого синдрома построим упомянутые выше последовательности номеров точек i и их разностей D_i для определения типа траекторий. Периодической последовательности D_i будет соответствовать траектория типа 3, аperiodической – траектория типа 4.

Алгоритм успешно апробирован на ряде известных динамических систем порядка $n = 3$ и $n = 7$, взятых из [5].

Работа выполнена при частичной финансовой поддержке гранта РФФИ (проект № 01-05-00391).

Литература

1. Ю.И. Неймарк, И.В. Котельников, Л.Г. Теклина. Исследование структуры фазового пространства динамической системы как задача распознавания образов. (Настоящий сборник).
2. Андронов А.А., Витт А.А., Хайкин С.Э. Теория колебаний. М.: Наука, 1981.
3. Неймарк Ю.И. Математические модели в естествознании и технике. Нижний Новгород, изд. Нижегородского университета, 2004.
4. Kotelnikov I.V. A Syndrome Recognition Method Based on Optimal Irreducible Fuzzy Tests and Syndromes. // Pattern Recognition and Image

- Analysis. Vol. 11. No. 3. 2001. pp. 553-559.
5. Неймарк Ю.И., Ланда П.С. Стохастические и хаотические колебания.
6. М.: Наука, главная редакция физ.-мат. литературы, 1987.

**Адаптивная модель распознавания образов для задач
оценивания и прогнозирования в условиях
неопределенности**

Б.М. Кувишинов

(Челябинск)

Точность решения задач оценивания и прогнозирования состояния динамических объектов существенно зависит от количества доступной и используемой при построении оценки (прогноза) информации о закономерностях их поведения. Использование методов распознавания образов позволяет привлечь такую информацию в виде конечного набора прецедентов, описывающих уже реализовавшиеся ранее состояния данного объекта и других объектов, имеющих аналогичные свойства. При этом для широкого круга прикладных задач характерно отсутствие точной информации по прецедентам, достаточной для построения обучающей выборки и решения задачи обучения по прецедентам в ее традиционной постановке. В таких условиях эффективным оказывается применение процедур адаптации решающих правил, обеспечивающих целенаправленную коррекцию недостоверной априорной информации.

Задачи оценивания и прогнозирования при использовании методов распознавания образов могут быть представлены в следующем виде. Имеется конечный набор из m прецедентов – различных состояний одного или нескольких объектов, априорная информация в каждом из которых представлена в виде значений некоторых измеряемых параметров состояния $X^0 = \{x_i \in \mathfrak{R}^n : i = \overline{1, m}\}$. Кроме того, заданы априорные экспертные оценки принадлежности объектов к классам для каждого прецедента $V^0 = \{v^0(x_i) \in \overline{1, K}\}$, где K – количество различных классов. Класс для прецедента указывает некоторые характеристики объекта, по которым нельзя получить прямые инструментальные измерения (в случае задачи оценивания), либо состояние, в которое перешел объект на прогнозном интервале времени (в случае задачи прогнозирования). Задача распознавания заключается в поиске решающего правила $v(a, ; ;)$, аппроксимирующего зависимость классов объектов от их априорного описания (x, v^0) :

$$v(a, x, v^0) : R(v(a, X^0, V^0), V^0) \rightarrow \min, a \in A, v(a, :, :) \in V, \quad (1)$$

где a – совокупность параметров решающих правил; R – функционал потерь при переходе от использования полного набора информации об объектах к описанию свойств объектов в форме решающего правила; A , V – заданные множества.

Существующие методы решения задачи (1) интерпретируют ее как задачу обучения, либо самообучения. В первом случае для решения задачи требуется полная априорная информация по представленным прецедентам, т.е. значения (x, v^0) должны быть заданы для каждого объекта обучающей выборки. Функционал потерь R строится таким образом, что решающее правило может точно аппроксимировать имеющиеся в прецедентах зависимости, однако наличие в них недостоверной информации не допускается. Во втором случае классы объектов априорно не заданы; вместо этого используются некоторые статистические или иные эмпирические предположения относительно законов распределения значений параметров, характеризующих состояние объектов.

В то же время существует широкий класс задач прогнозирования, в которых может быть сформирована обучающая выборка, содержащая по прецедентам информацию обоих видов X^0 и V^0 , однако включающая данные неопределенного характера. Неопределенность в данном случае предполагает наличие следующих свойств:

1) данные являются статистически неопределенными, т.е. неизвестны статистические законы распределения значений параметров состояния и классов объектов обучающей выборки;

2) информация по каждому прецеденту может быть неполной, неточной или искаженной, т.е. любое значение из (X^0, V^0) может быть пропущено, задано в виде интервала, либо измерено с погрешностью.

Для решения задачи распознавания в таких условиях предлагается организовать итерационный процесс адаптации, т.е. изменения и дополнения априорной информации:

$(X^{t+1}, V^{t+1}) = G(X^t, V^t)$, $t = 0, 1, \dots$ При этом преобразование G должно обеспечить выполнение условия

$$v(a, X^{t+1}, V^{t+1}) \rightarrow v^*(X^{t+1}) \text{ при } t \rightarrow \infty \quad (2)$$

где $V^* = v^*(X^*)$ – неизвестная совокупность точных значений принадлежности объектов к классам V^* для точных значений параметров состояния X^* .

Результатами решения задачи адаптации должны быть уточненные согласованные значения принадлежности к классам V для представленной выборки объектов и решающее правило $v(a, \cdot)$, позволяющее классифицировать новые прецеденты по априорной информации вида X .

Поскольку в явном виде проверить условие (2) нельзя, предлагается использовать функционал потерь R в качестве меры несогласованности каждого элемента априорной информации со всем объемом данных, содержащихся в обучающей выборке. С этой целью построена модель адаптации коллективного решающего правила, т.е. решающего правила вида $v(a, x, v) = L(\{v_q(x, v), q = \overline{1, Q}\})$ к недостоверной априорной информации. Отдельные решающие правила, входящие в состав коллективного решения, задают различные классификации для объектов анализируемой выборки. При выборе $v_q(a, \cdot)$ из достаточно ограниченного функционального класса каждое из них может классифицировать в соответствии с априорной классификацией только часть объектов выборки. Тогда относительно каждого объекта можно задать функционал несогласованности класса, присвоенного объекту априорно, с классами, задаваемыми для него отдельными решающими правилами $v_q(a, \cdot), q = \overline{1, Q}$. В совокупности эти показатели формируют матрицу несогласованности решений и задача адаптации сводится к поиску положения решающих правил, обеспечивающего минимум некоторой аддитивной функции от функционала потерь по всем элементам этой матрицы.

Разработана алгоритмическая реализация рассмотренной процедуры адаптации [1], позволяющая строить кусочно-линейные (комитетные) решающие правила. Эффективность предложенной модели подтверждается результатами решения практических задач медицинской и технической диагностики [1,2], прогнозирования объемов продаж на рынке сотовой связи [3].

Работа поддержана грантом РФФИ-Урал №04-01-96078.

Литература

1. Кувшинов Б.М., Шапошник И.И., Ширяев В.И., Ширяев О.В. Использование комитетов в задачах распознавания образов с

- неточными экспертными оценками // Изв. РАН. Теория и системы управления. 2002. №5. С. 87–94.
2. Кувшинов Б.М., Ширяев В.И. Об использовании адаптивных процедур распознавания образов в задачах поддержки принятия решений // Сб. тр. 15-й науч.-техн. конф. «Экстремальная робототехника» (С.-Петербург, 6-7 апреля 2004 г.). СПб.: СПбГТУ, 2004.
 3. Блинов А.Б., Коблов А.И., Кувшинов Б.М., Ширяев В.И. Модели прогнозирования развития региональных рынков сотовой связи стандарта GSM // Маркетинг в России и за рубежом. 2005. №5. (в печати)
 4. Khachai M.Yu., Mazurov V.D., Rybin A.I. Committee constructions for solving problems of selection, diagnostics, and prediction // Proc. of the Steklov Institute of Math. 2002, №1. P.67–101.

**Машинное обучение на данных, представленных
помеченными графами**
С.О. Кузнецов, М.В. Самохин
(Москва)

Введение и постановка задачи

В последние годы проблематика обучения на данных, заданных помеченными графами привлекает все большее внимание среди исследователей в области машинного обучения и разработки данных (data mining) [4,7,8,10]. Наш подход к решению данного вопроса основан на порождении замкнутых множеств помеченных графов и их приближений. С одной стороны при этом подходе вычисляются наиболее частные (наименее общие) обобщения положительных и отрицательных примеров, что зарекомендовало себя в реальных практических приложениях, в том числе в открытом соревновании по предсказательной токсикологии [4]. С другой стороны, порождение (частых) замкнутых подмножеств признаков оказалось полезным для вычисления множества ассоциативных правил, имеющих хорошую поддержку. Этот факт объясняет недавний рост интереса к вычислению замкнутых графов в области разработки данных. Так в работе [25] алгоритм Close-Graph, порождающий замкнутые графы, вычисляет все «частые» графы намного быстрее, чем предыдущая программа gSpan тех же авторов.

В докладе рассматриваются основные принципы обучения на данных, представленных помеченными графами и их приближениями, а также анализируются решения ряда прикладных задач по прогнозу свойств химических соединений, представленных химическими графами, с помощью разных методов машинного обучения: ДСМ-методом, методом порождения деревьев решений C4.5, наивным методом Байеса (в котором считается, что структурные признаки распределены независимо), а также

методом JRip, порождающим правила с исключениями.

Основные определения

В работе [2] была рассмотрена модель обучения из [3] в терминах АФП. В этой модели предполагается, что причина наличия целевого свойства связана с теми общими признаками, которые содержат описания всех объектов, обладающих этим свойством. В работе [5] были введены обобщенные определения ДСМ-гипотез для данных, на которых задана полурешеточная операция сходства.

Вкратце обучение гипотезам «с запретом на контрпример» выглядит следующим образом: для целевого признака имеются множества G^+ и G^- положительных и отрицательных примеров с описаниями, на которых задана полурешеточная (т.е. идемпотентная, коммутативная и ассоциативная) операция сходства $*$ и соответствующее ей отношение вложения. Для положительных примеров g_1, \dots, g_n и их описаний $\delta(g_1), \dots, \delta(g_n)$, соответственно, пересечение описаний $h = \delta(g_1) * \dots * \delta(g_n)$ положительных примеров g_1, \dots, g_n есть положительная гипотеза (с запретом на контрпример), подтверждаемая примерами g_1, \dots, g_n , если h не вкладывается в описание ни одного отрицательного примера g^- . Аналогично, определяются отрицательные гипотезы. Гипотезы используются для классификации примера g_t с неопределенным значением целевого свойства следующим образом: если существует такая положительная гипотеза h^+ , что h^+ вкладывается в описание g_t , то g_t классифицируется положительно. Отрицательная классификация определяется аналогично, возможны также противоречивая классификация и неопределенная классификация (детали см. в [3]).

Отношение порядка на помеченных графах в простейшем случае задается отношением изоморфизма подграфу: $\Gamma_2 \leq \Gamma_1$, если Γ_2 изоморфен подграфу Γ_1 . В общем случае, порядок учитывает порядок на метках вершин и ребер.

Операция пересечения $*$ на множествах графов задается следующим образом: для пары графов X и Y из G , $\{X\} * \{Y\} := \{Z \mid Z \leq X, Y, \forall Z^* \leq X, Y \ Z^* * Z\}$ (множество всех максимальных общих подграфов графов X и Y). В общем случае, $\{X_1, \dots, X_k\} * \{Y_1, \dots, Y_m\} := \text{MAX}_{\leq} (\{X_i\} * \{Y_j\})$, где $\text{MAX}_{\leq}(Z)$ выбирает максимальные элементы из множества Z .

Определения стандартных методов обучения C4.5, Naïve Bayes, JRip можно найти, например, в книге по коллекции методов машинного обучения WEKA [9].

Так как проверка отношения \leq на помеченных графах является NP-полной задачей, в [5] были определены операторы проекций, используемые для приближенного описания. Отображение $\psi : G \rightarrow G$

называется оператором проекции, если выполнены следующие условия: 1) если $x \sqsupseteq y$, то $\psi(x) \sqsupseteq \psi(y)$ (монотонность), 2) $\psi(x) \sqsupseteq x$ (сжатие), и 3) $\psi(\psi(x)) = \psi(x)$ (идемпотентность).

Любая проекция ψ полной полурешетки $(G, *)$ сохраняет операцию $*$, т.е., для любых $X, Y \in G$, $\psi(X * Y) = \psi(X) * \psi(Y)$, что позволяет установить связь между гипотезами и классификациями в исходном представлении и в его приближенном описании, полученном с применением оператора проекции.

Компьютерные эксперименты

Были проведены многочисленные компьютерные эксперименты по предсказанию биологических свойств химических соединений из нескольких химических рядов с использованием представления соединений в виде графов и в виде дескрипторного языка ФКСП (в котором соединение кодируется с помощью набора априори заданных признаков) [1] с помощью четырех методов машинного обучения. Результаты компьютерных экспериментов позволяют утверждать о состоятельности подхода, основанного на операторе проекции графов, поскольку он значительно сокращает временные затраты на анализ данных обучающей выборки и последующее применение полученных гипотез, с целью классификации, к данным тестовой выборки, в тоже время не приводя к большим информационным потерям (т.е. неправильным классификациям). Вместе с тем, эксперименты показывают оправданность редуцирования таблиц данных, при котором удаляются столбцы, являющиеся произведением других столбцов. Редуцирование контекста не приводит к изменениям результатов ДСМ-метода, приводит к несущественным изменениям результата метода порождения деревьев решений (5-10%) и приводит к малым изменениям (5-20%) для наивного метода Байеса и JRip.

Литература

1. Блинова В.Г. и Добрынин Д.А. Языки представления химических структур в интеллектуальных системах для конструирования лекарств // НТИ сер.2, №6, 2000.
2. Кузнецов С.О. и Финн В.К. О модели обучения и классификации, основанной на операции сходства // Обзорение Прикладной и Промышленной Математики 3, №1, 1996.
3. Финн В.К., Правдоподобные рассуждения в интеллектуальных системах типа ДСМ // Итоги науки и техники. Сер. Информатика. – Т. 15, М.: ВИНТИ, 1991.
4. Blinova V.G., Dobrynin D.A., Finn V.K., Kuznetsov S.O., and Pankratova E.S., Toxicology analysis by means of the JSM-method // Bioinformatics, №19, 2003.
5. Ganter B. and Kuznetsov S.O., Pattern Structures and Their Projections, 152

- Proc. 9th Int. Conf. on Conceptual Structures, ICCS'01, G. Stumme and H. Delugach, Eds., Lecture Notes in Artificial Intelligence, 2120, 2001.
6. Ganter B. and Wille R. Formal Concept Analysis. Mathematical Foundations, Springer, 1999.
 7. Grigoriev P.A., Yevtushenko S.A. and Grieser G. QuDA, a data miner's discovery environment // Technical Report AIDA 03 06, FG Intellektik, FB Informatik, Technische Universität Darmstadt, , September 2003.
 8. Inokuchi A., Washio T. and H. Motoda. Complete Mining of Frequent Patterns from Graphs: Mining Graph Data // Machine Learning, 50(3), 2003.
 9. Witten I.H. and Frank E. Data Mining: Practical Machine Learning Tools with Java Implementations. Morgan Kaufmann, 2000
 10. Yan X. and Han J. CloseGraph: mining closed frequent graph patterns. Proc. of the 9th ACM SIGKDD Int. Conf. on Knowledge Discovery and Data Mining, KDD'03. L. Getoor, T.E. Senator, P. Domingos and C. Faloutsos, Eds. ACM Press, 2003.

Многоуровневая структура данных и быстрый поиск на основе последовательных приближений

М.М. Ланге, С.Н. Ганебных

(Москва)

Многие задачи классификации данных и распознавания образов решаются методом идентификации предъявляемых объектов с ближайшими эталонами. При этом ошибка идентификации не должна превышать допустимого значения, а вычислительные затраты на поиск эталона должны приближаться к минимально возможному. В данной работе предлагается новый подход к решению задачи идентификации, основанный на методах многоуровневого кодирования с допустимой погрешностью и декодирования по схеме последовательных приближений. Решение имеет степенную вычислительную сложность от размера описания объектов и обеспечивает малую вероятность ошибки.

Формальная постановка задачи

Пусть $\mathbf{A} = \{A_i, i = \overline{1, M}\}$ - множество объектов источника и для каждого объекта A_i существует рекурсивное пирамидальное представление

$$P(A_i) = \{P_{lk}(A_i), l = \overline{0, L}, k = \overline{1, N_l}\}, \quad (1)$$

в котором l -ый уровень $P_l(A_i) = \{P_{lk}(A_i), k = \overline{1, N_l}\}$ является описанием объекта, содержащим $N_l = p^l$ сегментов, где $p \geq 2$ - целочисленный параметр рекурсии. Предполагается, что каждый сегмент

$P_k(A_i)$ в представлении (1) описывается n признаками, принимающими значения $0, 1, \dots, m-1$. Примером таких представлений являются квадропирамиды многоуровневых изображений [5]. Аналогичные представления могут быть построены для двумерных геометрических форм [3],[4].

Для любой пары объектов A_i и A_j , представленных в форме (1), вводятся меры различия l -го уровня

$$D_l(A_i, A_j) = \frac{1}{N_l} \sum_{k=1}^{N_l} d(P_k(A_i), P_k(A_j)) \quad (2)$$

с функцией потерь $0 \leq d(P_k(A_i), P_k(A_j)) \leq 1$, $l = \overline{0, L}$. При заданном $\varepsilon \geq 0$, мере (2) L -го уровня (с максимальным разрешением) соответствует ε -сеть [2]

$$\mathbf{P}_L(\mathbf{A}_\varepsilon) = \{P_L(A_j), A_j \in \mathbf{A}_\varepsilon\} \quad (3)$$

множества эталонов $\mathbf{A}_\varepsilon = \{A_j, j = \overline{1, M_\varepsilon}\}$, которая образована центрами областей $S_\varepsilon(P_L(A_j)) = \{P_L(A_i) : D_L(A_i, A_j) \leq \varepsilon\}$, покрывающих множество представлений L -го уровня $\mathbf{P}_L(\mathbf{A}) = \{P_L(A_i), i = \overline{1, M}\}$.

В терминах ε -сети (3) задача идентификации любого объекта $A_i \in \mathbf{A}$ эталоном $A_j \in \mathbf{A}_\varepsilon$ с допустимым отклонением ε сводится к процедуре поиска эталона, удовлетворяющего критерию

$$A_i \rightarrow A_j : D_L(A_i, A_j) \leq \varepsilon. \quad (4)$$

Требуется, чтобы вычислительная сложность процедуры поиска (4) имела порядок $O(N_L^a)$, где $a \geq 1$ -константа, зависящая от ε и параметров алгоритма поиска. Поскольку поиск с указанной степенной сложностью не всегда приводит к ближайшему эталону, возможны ошибочные решения, для которых неравенство в (4) выполняется с обратным знаком. Многоуровневая структура множества эталонов, позволяет обеспечить достаточно малую вероятность таких ошибок.

Основные результаты

Благодаря пирамидальной структуре представлений (1), ε -сеть (3) продуцирует иерархию сетей более низких уровней $l = L-1, L-2, \dots, 0$ по соответствующим мерам $D_l(A_i, A_j)$ вида (2). Поэтому поиск эталона, удовлетворяющего критерию (4), может быть выполнен методом

последовательной минимизации мер $D_l(A_i, A_j)$ на уровнях $l = 0, 1, \dots, L$.

Для организации такого поиска представления вида (1) подвергаются кодированию q -ичными ($q = m^n$) кодовыми словами $W_p(A_i) = B_{P_0}(A_i), \dots, B_{P_L}(A_i)$, содержащими $L + 1$ блоков. Каждый блок $B_{P_l}(A_i)$ имеет длину $N_l = p^l$ в q -ичных символах, описывающих сегменты в представлении l -го уровня $P_l(A_i)$. Кодовое слово $W_p(A_i)$ формируется последовательным считыванием q -ичных описаний сегментов в порядке возрастания номеров l и k в представлении (1). Лексикографическая сортировка и группирование кодовых слов узлов \mathcal{E} -сети (3) позволяет записать множество эталонов \mathbf{A}_ε в виде $(L + 1)$ -уровневого q -ичного кодового дерева $T_p(\mathbf{A}_\varepsilon) = \{W_p(A_j), A_j \in \mathbf{A}_\varepsilon\}$, в котором l -ый уровень представлен блоком $B_{P_l}(\mathbf{A}_\varepsilon)$ длины $N_l = p^l$.

Поиск в дереве $T_p(\mathbf{A}_\varepsilon)$ ближайшего эталона $A_j \in \mathbf{A}_\varepsilon$ к предъявленному объекту $A_i \in \mathbf{A}$ сводится к декодированию кодового слова $W_p(A_i)$ словом $W_p(A_j)$, доставляющим минимальные значения мер $D_l(A_i, A_j)$, $l = \overline{0, L}$. Эта процедура выполняется алгоритмом Витерби [1].

Для обеспечения степенной вычислительной сложности поиска, в каждом блоке $B_{P_l}(\mathbf{A}_\varepsilon)$ дерева $T_p(\mathbf{A}_\varepsilon)$ реализуется пошаговая процедура поиска с глубиной просмотра $S_l = \min(cl + b, p^l)$, $l = \overline{0, L}$, где $c \geq 0$ и $b \geq 0$ -целочисленные параметры. При $L \rightarrow \infty$ сложность алгоритма, измеряемая числом просматриваемых ветвей, удовлетворяет оценке

$$C < \frac{p}{p-1} \frac{2^{(1+b)\frac{p-1}{p}R(\varepsilon)}}{2^{\frac{p-1}{p}R(\varepsilon)} - 1} N_L^{1+c\frac{p-1}{p}R(\varepsilon)},$$

где $R(\varepsilon) = \frac{1}{N_L} \log_2 M_\varepsilon$ - скорость \mathcal{E} -сети эталонов (3) в битах на сегмент представления (1).

Численные оценки вероятности ошибочного решения получены для

рекурсивных пирамидальных представлений двоичных последовательностей с параметрами $m = 2, n = 1, p = 2, q = 2$ и меры различия с хемминговой функцией потерь $d(x, y) = x \oplus y$. При глубине поиска с параметрами $b = c = 1$ указанная вероятность не превосходит величины 0.1 и может быть уменьшена с увеличением значений b и c .

Работа выполнена при поддержке РФФИ (проект № 03-01-00538) и фонда НСФ (исследовательский проект по информационным технологиям 2005 г.).

Литература

1. Блейхут Р. Быстрые алгоритмы цифровой обработки сигналов // М.: Мир, 1989.
2. Колмогоров А. Н., Тихомиров В. М. \mathcal{E} -энтропия и \mathcal{E} -емкость множеств в функциональных пространствах // Теория информации и теория алгоритмов.- М.: Наука, 1987.
3. Berretti S., Del Bimbo A. Multiresolution spatial partitioning for shape representation // Proc. 17-th Intern. Conf. Pattern. Recogn., Cambridge, UK.- ICPR-2004, vol. 2, pp. 775-778.
4. Lange M. M., Ganebnykh S. N. Tree-like data structures for effective recognition of 2-D solids // Proc. 17-th Intern. Conf. Pattern. Recogn., Cambridge, UK.- ICPR-2004, vol. 1, pp. 592-595.
5. Rosenfield A. Pyramids: Multiresolution image analysis // Proc. 3-d Scandinavian Conf. Image Anal., Copenhagen.- SCIA-1983, pp. 23-28.

Синтез и анализ непараметрических систем классификации множеств случайных величин

В.А. Ланко
(Красноярск)

Введение

Непараметрические алгоритмы классификации множеств случайных величин впервые были предложены и исследованы в работе [1]. Идея подхода заключается в замене операций над множествами X на преобразования статистических оценок функций распределения их элементов $\bar{F}(x) \forall x \in R^k$ с помощью методов непараметрической статистики.

С этих позиций непараметрическое решающее правило классификации, например, в двувальтернативной задаче распознавания образов представляется в виде

$$\bar{m}_{12}(x) : \begin{cases} X \in \Omega_1, \text{ если } \bar{f}_{12}(X) \geq 0 \\ X \in \Omega_2, \text{ если } \bar{f}_{12}(X) < 0, \end{cases}$$

где оценка уравнения разделяющей поверхности

$$\bar{f}_{12}(X) = \left(n \prod_{v=1}^k D_{\beta_v} \right)^{-1} \sum_{i=1}^n \sigma(i) \prod_{v=1}^k \Phi \left(\frac{\max |\bar{F}(x) - \bar{F}_i(x)|}{D_{\beta_v}} \right) \quad (1)$$

восстанавливается по обучающей выборке $(X^i, \sigma(i), i = \overline{1, n})$ объёма n при $\sigma(i) = 1 (-1)$, если $X^i \in \Omega_1 (X^i \in \Omega_2)$,

$$\Phi \left(\frac{\max |\bar{F}(x) - \bar{F}_i(x)|}{D_{\beta_v}} \right) = \begin{cases} 1, \text{ если } |\bar{F}(x) - \bar{F}_i(x)| < D_{\beta_v} \\ 0, \text{ если } |\bar{F}(x) - \bar{F}_i(x)| > D_{\beta_v}. \end{cases}$$

Основные и значительные временные затраты при использовании решающего правила $\bar{m}_{12}(X)$ связаны с построением и проверкой гипотезы о тождественности эмпирических функций распределения $\bar{F}(x_v), \bar{F}_i(x_v)$ признаков элементов множеств $X, X^i, i = \overline{1, n}$ в соответствии с критерием Смирнова (D_{β_v} - пороговое значение критерия).

Возникает проблема повышения вычислительной эффективности непараметрических алгоритмов классификации множеств случайных величин, которая в работе решается на основе применения последовательных процедур формирования решений.

Исследования выполнены в рамках гранта РФФИ №03-01-00081.

Синтез «быстрого» алгоритма классификации

Определим центры \bar{x}^i множеств X^i . Компоненты центров \bar{x}^i множеств X^i определяются как средние значения признаков x_v , вычисляемых по выборкам $(x_v^j, j = \overline{1, n_i}, v = \overline{1, k}), i = \overline{1, n}$. Сформируем обучающую выборку $V_1 = (\bar{x}^i, \sigma(i), i = \overline{1, n})$ для построения решающего правила

$$\bar{m}_{12}(\bar{x}) : \begin{cases} \bar{x} \in \Omega_1, \text{ если } \bar{f}_{12}(\bar{x}) \geq 0 \\ \bar{x} \in \Omega_2, \text{ если } \bar{f}_{12}(\bar{x}) < 0, \end{cases}$$

где

$$\bar{f}_{12}(\bar{x}) = \left(n \prod_{v=1}^k c_v \right)^{-1} \sum_{i=1}^n \sigma(i) \prod_{v=1}^k \Phi \left(\frac{\bar{x}_v - \bar{x}_v^i}{c_v} \right).$$

Здесь $\Phi(\cdot)$ - ядерные функции, удовлетворяющие свойствам положительности, симметричности относительно \bar{x}^i и нормированности [1]; c_v - коэффициенты размытости ядерных функций, значения которых $c_v(n) \rightarrow 0$ при $n \rightarrow \infty$.

Решающее правило $\bar{m}_{12}(\bar{x})$ обладает высокой вычислительной эффективностью. Однако, обоснованное его применение возможно только при симметричных законах распределения элементов классифицируемых множеств.

Заметим, что значение ошибки классификации формируется в области пересечения классов Ω_{12} . Поэтому определим в Ω_{12} решающее правило $m'_{12}(X)$. С этой целью организуем вычислительный эксперимент на основе алгоритма $\bar{m}_{12}(\bar{x})$ для формирования обучающей выборки $V_2 = (X^i, \sigma(i), i \in I_{12})$, элементы которой принадлежат области пересечения классов Ω_{12} .

На основе V_2 построим решающее правило $\bar{m}'_{12}(X)$ с использованием непараметрической оценки уравнения разделяющей поверхности типа (1)

Тогда «быстрый» алгоритм классификации множеств случайных величин представляется следующей последовательной процедурой формирования решения

$$\bar{M}(X) : \begin{cases} X \in \Omega_1, \text{ если } \bar{f}_{12}(\bar{x}) \geq 0 \text{ и } \bar{p}_2(\bar{x}) = 0, \\ X \in \Omega_2, \text{ если } \bar{f}_{12}(\bar{x}) < 0 \text{ и } \bar{p}_1(\bar{x}) = 0, \\ \text{иначе перейти к алгоритму } \bar{m}'_{12}(X). \end{cases}$$

Отметим, что ошибки распознавания образов алгоритмов $\bar{M}(X)$ и

$\bar{m}_{12}(X)$ совпадают. Однако, вычислительная эффективность $\bar{M}(X)$ выше, так как значительно сокращаются временные затраты на проверку гипотезы о тождественности эмпирических функций распределения из обучающей выборки и закона распределения элементов контрольного множества.

Модификации алгоритма классификации

Рассматриваются возможности повышения вычислительной эффективности непараметрических алгоритмов классификации множеств случайных величин за счёт сокращения количества задач

$$H_0: \bar{F}_i(x) \equiv \bar{F}(x), \quad i \in I_{12}$$

в процессе функционирования алгоритма $\bar{m}'_{12}(X)$.

Предлагается в критерии Смирнова использовать соотношение $D_{\beta_v} < \left| \bar{P}_v^i - \bar{F}(\bar{x}_v) \right|$, как условие не выполнения гипотезы H_0 , где

$$\bar{P}_v^i = \bar{F}_i(\bar{x}_v), \quad v = \overline{1, k}, \quad i \in I_{12}.$$

Развита методика синтеза непараметрических моделей анализа множеств случайных величин на новые условия распознавания образов, учитывающих априорные сведения о виде уравнения разделяющей поверхности между классами и наличие разнотипных данных в обучающей выборке. Теоретическую основу непараметрических классификаторов составляют принципы гибридного моделирования и методы локальной аппроксимации.

Наиболее перспективными направлениями применения разработанных непараметрических моделей является обработка больших массивов статистических данных, часто встречающиеся при исследовании медико-биологических и экологических систем.

Литература

1. Лапко А.В., Лапко В.А. Непараметрические методики анализа множеств случайных величин // Автометрия, 2003. - №1. – С.54-61.

Непараметрические и гибридные системы классификации разнотипных данных

А.В. Лапко, В.А. Лапко

(Красноярск)

Аннотация

Предлагается методика синтеза гибридных моделей распознавания образов, обеспечивающих эффективное использование априорных

сведений о виде уравнения разделяющей поверхности между классами и информации обучающей выборки. С позиций последовательных процедур формирования решений рассматриваются многоуровневые системы классификации разнотипных данных.

Синтез гибридных моделей распознавания образов

Пусть при решении, например, двухальтернативной задачи распознавания образов кроме обучающей выборки $V = (x^i, \sigma(x^i), i = \overline{1, n})$ имеются априорные сведения $F_{12}(x, \alpha)$ о виде уравнения разделяющей поверхности $f_{12}(x)$ между классами Ω_1, Ω_2 в пространстве $x \in R^k$. Знание $F_{12}(x, \alpha)$ предполагает наличие решающего правила классификации

$$m_{12}^F : \begin{cases} x \in \Omega_1, & \text{если } F_{12}(x, \alpha) \leq 0, \\ x \in \Omega_2, & \text{если } F_{12}(x, \alpha) > 0, \end{cases} \quad (1)$$

по тем или иным причинам не удовлетворяющего исследователя. Информация обучающей выборки V формируется на основании данных о значениях признаков n объектов и соответствующим им «указаний учителя» $\sigma(x)$.

Для эффективного использования априорной информации $(F_{12}(x, \alpha), V)$ воспользуемся принципами гибридного моделирования, обеспечивающих сочетание в обобщенном решающем правиле классификации преимуществ непараметрических и локальных методов аппроксимации.

Построение гибридного алгоритма распознавания образов предполагает выполнение следующих действий:

1. Определить (либо уточнить) параметры α уравнения разделяющей поверхности $F_{12}(x, \alpha)$ решающего правила (1) из условия минимума эмпирической ошибки распознавания образов.

2. По результатам вычислительного эксперимента сформировать выборку $V_1 = (x^i, q(x^i), i = \overline{1, n})$ расхождений между решениями $\bar{\sigma}(x^i)$ правила (1) и «указаниями учителя» $\sigma(x^i)$ обучающей выборки V . При этом значения функции расхождений

$$q(x^i) = \begin{cases} 0, & \text{если } \sigma(x^i) = \bar{\sigma}(x^i), \\ F_{12}(x^i, \bar{\alpha}) + \Delta, & \text{если } \bar{\sigma}(x^i) = 1, \text{ а } \sigma(x^i) = -1, \\ -(F_{12}(x^i, \bar{\alpha}) + \Delta), & \text{если } \bar{\sigma}(x^i) = -1, \text{ а } \sigma(x^i) = 1. \end{cases}$$

Таким образом, при наличии ошибки функция расхождения принимает значение обратное по знаку уравнения разделяющей поверхности $F_{12}(x, \alpha)$ и превышает его на величину параметра Δ . Например, если ситуация x^i принадлежит второму классу ($\sigma(x^i) = 1$), а в соответствии с решающим правилом (1) $x \in \Omega_1$, т.е. $F_{12}(x^i, \bar{\alpha}) < 0$, то значение $q(x^i) = F_{12}(x^i, \bar{\alpha}) + \Delta$.

3. Осуществить синтез непараметрической оценки функции расхождения

$$\bar{q}(x) = \frac{\sum_{i=1}^n q(x^i) \beta_i(x)}{\sum_{i=1}^n \beta_i(x)}, \quad \beta_i(x) = \prod_{v=1}^k \Phi\left(\frac{x_v - x_v^i}{c_v}\right),$$

где $\Phi(\cdot)$ - ядерная функция, удовлетворяющая условиям положительности, симметричности и нормированности [1].

4. Построить гибридный алгоритм классификации

$$\bar{m}_{12}(x) : \begin{cases} x \in \Omega_1, & \text{если } \bar{f}_{12}(x) \leq 0, \\ x \in \Omega_2, & \text{если } \bar{f}_{12}(x) > 0, \end{cases} \quad (2)$$

$$\bar{f}_{12}(x) = F_{12}(x, \bar{\alpha}) + \bar{q}(x).$$

Оптимизация алгоритма (2) по параметрам $c_v, v = \overline{1, k}$ и Δ осуществляется из условия минимума статистической оценки ошибки распознавания образов типа (2).

Методика классификации в пространстве разнотипных признаков

Для «обхода» проблем обработки разнотипных данных в задаче распознавания образов используются условно-последовательные процедуры классификации.

Пусть $x = (x(t), t = \overline{1, T})$ - описание классифицируемой ситуации, состоящее из групп однотипных признаков $x(t), t = \overline{1, T}$, измеренных в одной и той же шкале; $m_t(x(t), \alpha_t)$ - решающие правила в пространстве $x(t), t = \overline{1, T}$, α_t - их параметры.

Идея предлагаемого подхода состоит в формировании наборов однотипных признаков из исходных, измеренных в различных шкалах, и сопоставлении им этапов последовательной процедуры принятия решений. При этом каждый последующий этап классификации осуществляется в области неоднозначных решений предыдущего этапа. Таким образом линейную структуру системы образуют этапы обработки исходной и промежуточной информации с помощью локальных распознающих устройств, а взаимосвязи между ними отражают порядок формирования конечного решения.

Локальные алгоритмы распознавания образов $m_t(x(t), \alpha_t)$ продолжают решение целевой задачи в пространстве $x(t)$ при условии принадлежности $x(t-1)$ области ошибочной классификации (в противном случае – решение принято на $(t-1)$ -м этапе распознавания).

При построении многоуровневой системы распознавания образов могут использоваться известные решающие правила классификации в пространстве однотипных признаков, тем самым соблюдается принцип преемственности научных исследований.

Литература

1. Лапко А.В., Лапко В.А., Соколов М.И., Ченцов С.В. Непараметрические системы классификации. – Новосибирск: Наука, 2000. – 192 с.

Прогнозирование экстремальных событий в классе логических решающих функций

Г.С. Лбов, В.Б. Бериков

(Новосибирск)

В настоящее время существует достаточно большое число методов прогнозирования экстремальных событий. Большинство методов использует различные вероятностные модели, теорию марковских процессов, теорию случайных точечных процессов и т.д. При использовании данных методов обычно предполагается, что исходная информация представляет собой реализацию случайного одномерного или

двумерного процесса. Однако, с нашей точки зрения, для анализа и прогнозирования реальных явлений и событий следует учитывать следующие особенности:

1. Методы прогнозирования должны использовать комплексное описание, содержащее информацию не только о самом процессе, но и о других факторах, потенциально влияющих на этот процесс.

2. Реальные данные могут содержать не только количественную, но и качественную информацию, т.е. многомерные временные ряды, включающие числовые, символьные, булевы последовательности.

3. Задачу необходимо решать в условиях, когда имеющиеся ряды имеют относительно малую длину.

4. Экстремальные ситуации по своей сути являются редкими событиями, поэтому количество соответствующих им прецедентов в эмпирической информации мало по отношению к общему объему выборки.

В данной статье для прогнозирования экстремальных ситуаций используется построение логико-вероятностных моделей [1, 2], учитывающих указанные особенности. Предлагаемый подход предполагает построение логико-вероятностных моделей изучаемых объектов или явлений с целью прогнозирования экстремальных ситуаций. Логико-вероятностные модели строятся в классе логических решающих функций от разнотипных переменных и представляются списком логических закономерностей («знаний»), отражающих внутренние причинно-следственные связи сложных объектов или явлений и обладающих достаточно высокой прогнозирующей способностью. Такого рода закономерности близки к естественному языку логических суждений, что существенно облегчает совместную обработку результатов статистической обработки и знаний экспертов.

Логико-вероятностную модель удобно представлять в виде дерева решений или дерева событий (см пример на рис.1, сформированный на основе материалов [3]). Дерево событий (называемое также деревом отказов, ошибок) часто используют при анализе потенциально опасных событий (технологических катастроф, экстремальных явлений природы и т.д.). Дерево событий позволяет в графическом виде представить иерархию последовательно происходящих случайных событий, которые приводят к возникновению некоторого нежелательного события.

На основе анализа дерева событий может быть получен прогноз возникновения события, выработаны меры по его предотвращению. Как правило, дерево событий формирует эксперт на основе своего опыта и другой априорной информации о данном событии и других аналогичных событиях. Часто эксперт может использовать статистическую информацию, описывающую изучаемый объект и другие подобные ему

объекты. Эта информация может быть также использована для построения дерева.

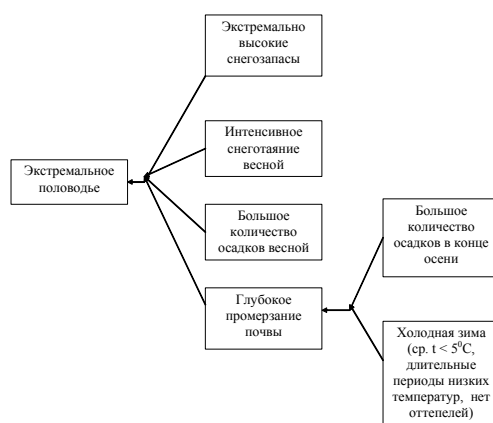


Рис 1.
Пример дерева событий для прогнозирования половодья в западной части России

Предлагается [4] метод построения дерева событий (или формирования некоторых его фрагментов, для нахождения которых требуется анализ статистических данных) с помощью анализа многомерного временного ряда, описывающего динамические свойства объекта. Суть предлагаемого метода заключается в использовании алгоритмов распознавания динамических объектов, основанных на деревьях решений [1,2].

Для проверки работоспособности разработанного алгоритма был проведен вычислительный эксперимент. Случайным образом генерировались две булевы и одна числовая последовательность, независимые друг от друга. Длина последовательностей была равна 1000. Полагалось, что при определенном заданном сочетании предыдущих значений этих последовательностей возникает нежелательное событие, а во всех остальных случаях это событие не возникает. Таким образом, формировалась булева последовательность, обозначающая наличие или отсутствие нежелательного события (доля нежелательных событий составляла около 0,08).

Полученные последовательности подавались на вход алгоритма, на выходе которого формировалось дерево событий. Для оценки качества алгоритма генерировалась контрольная выборка. Оказалось, что в среднем алгоритм в 99 процентах случаев правильно прогнозировал возникновение событий.

В следующем эксперименте дополнительно к предыдущему варианту предполагалось, что среди значений обучающих последовательностей

имеется 5% пропусков (неизмеренных значений). Местонахождение пропусков выбиралось случайно. В среднем в 97% случаев алгоритм правильно определял возникновение событий.

Использование логико-вероятностных моделей позволяет распознавать не только экстремальные ситуации, но и те, с которыми связаны наибольшие потери (предполагается, что функция потерь задана экспертом). С математической точки зрения это означает, что для экстремальных ситуаций требуется прогнозировать не только соответствующий класс, но и значение заданной на объектах целевой функции. В работе [5] предложен метод, в принципе позволяющий прогнозировать уникальные ситуации, когда значение целевой функции превосходит значения, достигавшиеся ранее.

Разработанные методы в рамках данного подхода были использованы для прогноза стоков рек Сибири, в том числе прогноза экстремальных ситуаций. В частности, оценивалась вероятность возникновения в марте экстремальной по маловодью. Были обработаны среднемесячные данные замеров стока реки Обь за период с 1922 по 2000 гг. При прогнозировании маловодий (г. Барнаул, Колпашево) среднее число ошибок 1-го и 2-го рода на скользящем экзамене составило 7% и 18% соответственно.

Работа выполнена при поддержке РФФИ (грант 04-01-00858а).

Литература

1. Лбов Г.С., Старцева Н.Г. Логические решающие функции и вопросы статистической устойчивости решений. Изд-во Института математики СО РАН, Новосибирск, 1999.
2. Бериков В.Б. Анализ статистических данных с использованием деревьев решений. Изд-во НГТУ, Новосибирск, 2002.
3. Л.С.Кучмент, А.Н.Гельфанд. Динамико-стохастические модели формирования речного стока. М.: Наука. 1993.
4. Бериков В.Б. Построение дерева причин на основе анализа многомерного временного ряда // Вычислительные технологии. Том 9. Вестник КазНУ им. аль-Фараби. Серия математика, механика, информатика. №3 (42). Часть 1. (Совм. выпуск) 2004. С. 305-310.
5. Lbov G.S., Gerasimov M.K. A Method of Extreme Situations Forecasting Based on Multiple Time Series Analysis // Proc. of VII International Conference "Computer Data Analysis And Modeling". Minsk, 2004, pp. 231-234.

Об эффективном поиске оптимального группового слагаемого для набора метрических конфигураций

А.И. Майсурадзе

(Москва)

В настоящее время в распознавании образов и прогнозировании широкое распространение получило использование различных мер сходства, т.е. описание объектов оказывается связанным с попарным сравнением этих объектов между собой. Оценки сходства или различия объектов используются как в теории распознавания и прогнозирования (например, см. [1]), так и при решении конкретных прикладных задач.

Во многих задачах меры сходства вычисляются только для конечного множества объектов распознавания. В таком случае принято говорить о конфигурациях сходства. Если результатом попарного сравнения объектов является числовая оценка, которая интерпретируется как расстояние между этими объектами, то соответствующую конфигурацию сходства называют метрической конфигурацией (МК). В последние годы можно говорить о появлении в распознавании образов комплекса технических приемов, предназначенных для работы с МК.

Отдельного внимания заслуживают методы работы с МК, которые опираются на тот факт, что МК можно отождествить с элементами специального линейного векторного пространства (ЛВП, см. [2]). Традиционным способом представления метрической конфигурации является матрица попарных расстояний. Эта матрица симметрична, на её главной диагонали находятся нули. В [2] любая матрица, удовлетворяющая двум указанным свойствам, в том числе и матрица с отрицательными элементами, соответствует некоторой МК. Чтобы МК удовлетворяла аксиомам полуметрики, дополнительно требуется выполнение неравенств треугольника. Заметим, что неотрицательность элементов МК следует из выполнения неравенств треугольника. Множество МК, удовлетворяющих аксиомам полуметрики, называется полуметрическим конусом *МЕТ*.

Существенное значение играет тот факт, что в большинстве задач распознавания не существует некоторого единственного «объективного» способа наделять пространство объектов метрикой. В подобной ситуации одним из известных приемов является получение информации об одних и тех же свойствах одного и того же набора объектов из различных источников с последующим синтезом из полученной информации некоторых в том или ином смысле «согласованных» значений свойств. Следуя получившей широкое распространение терминологии из [3], для МК такие согласованные значения можно назвать групповыми.

Пусть для некоторого набора объектов (мощности m) имеется набор МК r_1, \dots, r_n (мощности n). В докладе рассматривается задача разложения

каждой r_i из заданного набора на общее «групповое слагаемое» s и индивидуальную поправку e_i :

$$r_1 = s + e_1, \quad \dots, \quad r_n = s + e_n. \quad (*)$$

Данному разложению можно приписать следующую интерпретацию: групповое слагаемое соответствует прикладной области в целом, а индивидуальные поправки – отдельным источникам или способам получения МК.

Очевидно, что в ЛВП для разложения (*) может быть использована произвольная МК s . Поэтому на групповое слагаемое и индивидуальные поправки следует наложить какие-либо ограничения. При работе с МК естественным представляется требовать выполнения аксиом полуметрики:

$$s \in MET, \quad e_1 \in MET, \quad \dots, \quad e_n \in MET. \quad (**)$$

Для задачи (*) с ограничениями (**) получен критерий разрешимости. Поскольку групповое слагаемое s однозначно определяет разложение (*), то ниже под множеством решений будет пониматься множество значений, которые может принимать s .

Ограничения (**) представляют собой систему из $(n+1)m(m-1)(m-2)/2$ линейных неравенств. Все эти ограничения можно переформулировать, как ограничения на s . Из них активными будут только $m(m-1)(m-2)$ неравенств, которые можно найти, затратив порядка $O(nm^3)$ арифметических операций. Получено описание структуры множества решений задачи (*, **).

Следуя интерпретации разложения (*), обычно необходимо найти не произвольное решение задачи (*, **), а такое, в котором групповое слагаемое является в некотором смысле наибольшим, наиболее удаленным от нулевой МК. Формализация указанного понятия приводит к поиску оптимального по Парето группового слагаемого или введению некоторого функционала «абсолютной величины» на МК, переходу к задаче линейного или квадратичного программирования. Решение задачи оптимизации может быть неединственным. Сложная структура экстремальных лучей полуметрического конуса требует тщательного выбора вычислительных методов для решения задачи оптимизации.

В [2] описан специальный способ представления МК, связанный с линейным разложением произвольной МК r по некоторой фиксированной системе МК K . Переход к такому представлению r' от матрицы попарных расстояний и обратно для некоторых классов систем МК может быть выполнен за $O(m^2)$ операций. При этом достаточным условием выполнения аксиом полуметрики будет неотрицательность указанного представления:

$$r' \geq 0 \Rightarrow r \in MET.$$

Зафиксируем некоторую подходящую систему K и потребуем неотрицательности представления для группового слагаемого и индивидуальных поправок:

$$s' \geq 0, \quad e_1' \geq 0, \quad \dots, \quad e_n' \geq 0. \quad (***)$$

Для задачи (*) с ограничениями (***) получен критерий разрешимости. Система неравенств (***) сильнее (**), хотя (***) содержит только $(n+1)m(m-1)/2$ неравенств. Из них активными будут только $m(m-1)$ неравенств, которые можно найти, затратив порядка $O(nm^2)$ арифметических операций.

Если рассматривать систему K как базис в специальном ЛВП МК, то множество решений задачи (*, ***) имеет достаточно простую структуру: это многомерный параллелепипед с ребрами, параллельными координатным осям. Нулевая МК является вершиной этого параллелепипеда. Вершина d' , находящаяся на противоположном от нулевой МК конце большой диагонали параллелепипеда, может быть найдена по формуле

$$d'_{jk} = \min_{i \in \{1, \dots, n\}} (r_i')_{jk},$$

где (jk) пробегают множество всех неупорядоченных пар индексов из $\{1, 2, \dots, m\}$. Таким образом, множество решений задачи (*, ***) можно записать в виде

$$0 \leq s' \leq d',$$

причем d' строится по исходному набору МК за $O(nm^2)$ операций. Кроме того, d' удовлетворяет требованию наибольшей удаленности от нулевой МК во всех указанных выше смыслах.

Работа выполнена при финансовой поддержке гранта Президента РФ по поддержке ведущих научных школ (НШ-1721.2003.1), в рамках программы фундаментальных исследований ОМН РАН «Алгебраические и комбинаторные методы математической кибернетики».

Литература

1. Журавлёв Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики, 1978. Вып. 33. С. 5-68.
2. Майсурадзе А.И. Об использовании нетривиальных базисов пространств метрических конфигураций в задачах распознавания // Интеллектуализация обработки информации: тез. докл. Симферополь: Крымский науч. центр НАН Украины, 2002. С. 58-60.
3. Дэйвисон М. Многомерное шкалирование // М.: Финансы и статистика, 1988.

Об одной системе экспертов, меняющейся во времени

В.Л. Матросов, Б.З. Угольникова

(Москва)

Пусть имеется некоторая группа, которая должна дать оценку определенному событию. Будем эту группу называть группой экспертов.

Изучается поведение группы экспертов при наличии системы связей между подгруппами в данной группе. Это означает, что мнение каждого эксперта зависит некоторым образом от мнений части остальных экспертов.

В каждый дискретный момент времени t оценки экспертов рассматриваются как последовательности натуральных чисел $(x_1(t), x_2(t), \dots, x_n(t))$, (1). Имеется набор начальных оценок $(x_1(0), x_2(0), \dots, x_n(0))$. Оценка i -ого эксперта в момент времени $(t + 1)$ есть некоторая функция от оценок определенной подгруппы экспертов в момент времени t

$$x_i(t + 1) = f_i(x_{i_1}(t), \dots, x_{i_k}(t)), \quad t = 1, 2, 3, \dots \quad i = 1, \dots, n,$$

где n - количество экспертов. В зависимости от выбора функций и соответствующих подгрупп (вообще говоря произвольных), система может выдавать всевозможные «цепочки» оценок. В качестве функций f_i можно рассматривать различные функции k -значной логики. Частный случай $k = 2$. Тогда оценки экспертов двух типов: «да», «нет»: $x(0) \in \{0, 1\}$.

Интерес представляют случаи, когда «цепочка» оценок (1) стабилизируется, то есть группа экспертов за определенное число шагов приходит к окончательному мнению. Число шагов, конечно, должна быть не слишком растущая от n функция. Также типичен случай, когда оценки представляют из себя периодические последовательности, то есть $x_i(t + k) = x_i(t)$, $i = 1, \dots, n$, где k - некоторое натуральное число. В таком случае систему надо несколько изменить, то есть изменить набор переменных для функции f_i или саму функцию (или несколько функций), для того, чтобы привести систему к стабилизации.

Такую систему можно применять для различных ситуаций в том случае, когда надо согласовать мнения экспертов и выдать окончательный ответ.

Утверждение.

Пусть
$$x_i(t + 1) = f(x_i(t), x_{k+1}(t), \dots, x_n(t)), \quad i = 1, \dots, k$$

$x_j(t+1) = g(x_j(t), x_1(t), \dots, x_k(t)), \quad j = k+1, \dots, n,$ где f, g монотонные функции и не константы. Тогда в цепочке (1) либо наступает стабилизация за 2 шага, либо цепочка заикливаясь после 2-х шагов с периодом 2.

Разработка логико-вероятностного метода описания и поиска закономерностей в пространственно-временных сигналах на основе логики первого порядка и медианного анализа

*А.А. Морозов, В.А. Морозов, Ю.В. Обухов, Т.А. Строганова,
М.М. Цетлин
(Москва)*

В статье рассмотрен новый логико-вероятностный метод описания и поиска закономерностей в сложных пространственно-временных сигналах, основанный на логике первого порядка и медианном анализе. Рассматриваемый метод разработан в Институте радиотехники и электроники РАН в рамках проекта исследования и разработки методов анализа биомедицинских экспериментальных данных, для решения практических задач анализа спектрограмм пространственно-временных сигналов – электроэнцефалограмм (ЭЭГ) человека [1,2].

Идея разработанного метода состоит в том, чтобы объединить дедуктивные возможности логического программирования (языка Пролог) и непараметрические статистические методы. Такое объединение возникло естественным образом в ходе экспериментов со спектрограммами ЭЭГ мозга и обусловлено следующими предпосылками:

1) В ходе экспериментов с ЭЭГ возникла практическая необходимость проверять наличие или отсутствие у отдельных образцов ЭЭГ, а также у наборов ЭЭГ некоторых свойств, описываемых в терминах логики первого порядка, например:

$$\exists t_1, t_2, t_3 : t_1 < t_2 < t_3 : A(t_1) > A(t_2), A(t_2) < A(t_3) ,$$

что означает: на спектрограмме существуют такие моменты времени t_1, t_2 и t_3 , что при переходе между ними амплитуда сигнала статистически значимо уменьшается, а затем снова увеличивается. Приведённая выше формула является одним из возможных вариантов логического определения свойства «на спектрограмме существует двойной пик».

2) Для поиска и проверки свойств, формализованных средствами логики первого порядка, традиционно используются методы и средства логического программирования, однако в данном случае использование стандартных методов невозможно, потому что атомарные предикаты \neq , $>$, $<$, \geq , \leq и др. должны иметь статистический смысл, а именно, должны

обозначать статистически значимые отличия выборок экспериментальных данных, относящихся к соответствующим пространственно-временным областям.

Таким образом, фактически, возникла необходимость реализовать логический вывод на аксиомах (отношениях), связывающих не числа, а выборки данных. При этом эксперименты с реальными ЭЭГ показали, что:

1) Выборки данных в нейрофизиологических экспериментах, как правило, не соответствуют нормальному закону распределения.

2) Обычно при анализе ЭЭГ возникает необходимость учитывать несколько независимых факторов, а именно: время, разновидность стимула, предъявляемого в ходе эксперимента, отведение (электрод), с которого записан сигнал, полушарие (левое или правое), рассматриваемый частотный диапазон сигнала, метод усреднения сигнала (со знаком, без знака и т.п.).

Для анализа экспериментальных данных, не соответствующих нормальному закону распределения, можно использовать (приблизённо) методы параметрической статистики, ориентированные на гауссовы случайные величины, или методы непараметрической статистики, свободные от каких-либо априорных предположений о виде распределения исследуемых величин. Однако и в том и в другом случае использование статистических методов сравнения выборок в ходе логического вывода практически осуществимо только при достаточно компактном описании массивов входных данных (выборок). Наивный подход к объединению логического программирования и математической статистики с помощью включения в логический язык встроенных процедур проверки статистических гипотез и полных массивов экспериментальных данных оказывается практически нереализуемым из-за огромного объёма данных, передаваемых в логическую программу, и неприемлемо больших расходов времени на проверку статистических гипотез при выполнении каждого элементарного сравнения.

Мы решили указанную проблему и выработали практически реализуемый подход к логико-вероятностному анализу сложных биомедицинских данных на основе методов медианного сравнения выборок.

Разработанный метод анализа включает следующие этапы и уровни:

1) Осуществляется предварительная обработка экспериментальных данных (ЭЭГ), включающая удаление глазодвигательных и мышечных артефактов, выбросов, а также устранение искажений данных, связанных с нестационарностью объекта измерений и аппаратных функций измерительной системы.

2) Вычисляются спектрограммы ЭЭГ.

3) По каждой выборке спектрограмм экспериментальных данных,

соответствующей определённой стимулу, отведению и частотному диапазону, вычисляются доверительные интервалы для оценок медианы спектрограмм с заданной вероятностью ошибки первого рода. Вычисление доверительных интервалов осуществляется непосредственно на основе эмпирического распределения выборки.

4) Вычисленные доверительные интервалы преобразуются в термы (элементы данных) логического языка Акторный Пролог [3].

5) Средствами языка Акторный Пролог описываются и проверяются логические свойства и закономерности спектрограмм ЭЭГ. При этом объектно-ориентированные средства языка Акторный Пролог помогают в значительной мере ускорить логический вывод на больших наборах данных за счёт того, что данные, относящиеся к разным испытуемым, могут быть представлены в виде отдельных пространств поиска. В результате этого, процесс перебора вариантов становится более целенаправленным, а пространство поиска, соответствующее отдельным ветвям логического вывода, уменьшается.

Одной из наиболее серьёзных проблем, возникших в ходе разработки рассматриваемого метода, оказалось то, что результатом вычисления спектрограмм сигналов, в общем случае, являются комплексные числа. Для решения этой проблемы нам понадобилось обобщить медианные методы сравнения выборок на комплексные значения. Разработанное обобщение медианных методов основано на следующих принципах:

1) Проверка статистических гипотез о равенстве комплексных значений основана на проверке доверительных интервалов оценок медианы отдельно для действительной и мнимой частей значений, с последующим объединением результатов по методу Бонферони.

2) Проверка статистических гипотез о том, что медианы выборок больше, меньше, больше или равны, меньше или равны, осуществляется с помощью сравнения скалярных метрик комплексных значений, вычисляемых на основе доверительных интервалов медиан действительных и мнимых частей этих значений.

В настоящее время разработанный логико-вероятностный метод реализован на базе объектно-ориентированного логического языка Акторный Пролог и используется для анализа экспериментальных нейрофизиологических данных, полученных в рамках совместного проекта ИРЭ РАН и Психологического института РАО.

Авторы выражают благодарность д.т.н. А.Я. Олейникову и к.ф.-м.н. А.В. Корженевскому за помощь в организации вычислений на кластере ИРЭ РАН. Работа поддержана РФФИ, проекты 03-01-00256 и 05-01-00651, а также программой Президиума РАН «Фундаментальные науки – медицине».

Литература

1. Морозов А.А., Обухов Ю.В., Строганова Т.А., Цетлин М.М., Прокофьев А.О. О проблеме поиска закономерностей в пространственно-временных сигналах коры мозга человека // Искусственный интеллект. – 2004. – №3. – С.499-509.
2. Morozov A.A., Obukhov Yu.V., Stroganova T.A., Tsetlin M.M., Orekhova E.V. The Search of the Regularity in the Spatio-Temporal Dynamics of the Human Visual Cortex Oscillations // Pattern Recognition and Image Analysis. – 2005. – Vol. 15. – № 3. – P. 1-3.
3. Морозов А.А. Введение в Акторный Пролог. – ИРЭ РАН: 2002. – http://www.cplire.ru/Lab144/start/r_index.html .

О методике распознавания плоских кривых

С.А. Мустафин

(Алматы)

Задача распознавания объектов изображений порождает появление новых алгоритмов и методов, которые позволяют, так или иначе, разрешить возникающие в задаче проблемы.

Распознавание кривых, произвольно расположенных на плоскости, на основе анализа формы излагается, как правило, на содержательном уровне. Опыт использования таких методик в практических задачах привел в итоге к формализации этапов ее реализации. Основой предлагаемой методики являются работы Морозова, Маркова, Фукса и др.

В данной работе мы приводим описание методики, которое позволяет придать точный смысл вводимым понятиям и процедурам, и создает возможность для разработки компьютерных программ, реализующих предложенную методику распознавания, относящую заданную кривую к тому или иному классу по ее форме или выдающую кривые, наиболее похожие на нее по форме.

Частоты встречаемости графических примитивов рассматриваются как существенные характеристики структуры кривых.

Определив матрицу частот встречаемости примитивов для каждой изучаемой кривой, вводится коэффициент различия, который вычисляется для пары кривых как сумма мер различия по всем соответствующим элементам двух матриц.

С помощью коэффициента удастся четко различить особенности некоторых кривых. Однако попытки использовать этот и подобные ему коэффициенты для оценки близости кривых могут оказаться неудачными. Чтобы избежать этого, положим в основу методики распознавания построение классификации примитивов по каждой кривой. Классификация строится по матрице частот встречаемости графических примитивов в кривой.

В методику встроены пункты для случаев, когда распознавание прошло неудачно и вводится поворот кривой.

Конкретизацию описанной схемы распознавания удобно проводить, формализовав введенные понятия совокупности существенных графических связей, общей части, критерия сравнения и т.д.

Практическая реализация предлагаемой методики показала неплохие результаты на «дизайнерских» кривых.

Предлагаемая методика определения близости плоских кривых по форме может найти успешное применение при решении различных практических задач. Примерами являются задачи сейсмологии, астрономии, обработки изображений, генетике и т.д.

Емкостная характеристика выбора подпространства признаков **В.М. Неделько** (Новосибирск)

Введение

Для повышения статистической надежности решающих функций в условиях малой выборки часто производится сокращение размерности исходного признакового пространства. Сокращение размерности как правило приводит к уменьшению емкости класса решающих функций и, соответственно, к повышению надежности.

Однако сужение признакового пространства может не только уменьшать, но и увеличивать полную емкость алгоритма построения решающей функции, особенно если подпространство выбирается полным перебором сочетаний для заданного числа переменных в соответствии с критерием минимизации эмпирического риска. Это возможно из-за того, что сама процедура выбора подмножества переменных имеет существенную емкость.

Настоящая работа посвящена исследованию емкости процедуры выбора подпространства для задачи классификации.

Введем следующие обозначения. Пусть $X = \mathbf{R}^d$ – пространство значений переменных, $Y = \{1, 2\}$ – множество классов. Решающей функцией назовем соответствие $f : X \rightarrow Y$.

Под задачей классификации будем понимать построение функции f на основе случайной независимой выборки $v = \{(x^i, y^i) \in D \mid i = \overline{1, N}\}$ из некоторого распределения в $D = X \times Y$.

Для любой (измеримой) функции f можно определить риск как

вероятность ошибки $R(f) = P(\{(x, y) \in D \mid f(x) \neq y\})$ и
 эмпирический риск $\tilde{R}(v, f) = \frac{1}{N} \left| \{(x^i, y^i) \in v \mid f(x^i) \neq y^i\} \right|$ как долю
 неверно классифицированных объектов выборки.

В качестве меры статистической надежности заданного метода построения решающих функций будем использовать смещение эмпирического риска, т.е. разность математических ожиданий риска и эмпирического риска $S = ER - E\tilde{R}$.

Оценки емкости

Под емкостью [1] класса решающих функций Φ будем понимать максимальное число способов классификации выборки заданного объема функциями из Φ .

Известно, что емкость класса линейных решающих функций составляет $C(d) = 2 \sum_{m=0}^d C_{N-1}^m$. – удвоенное число способов разбиения N точек

гиперплоскостями в пространстве размерности d .

Очевидно, емкость алгоритма классификации, осуществляющего выбор d' переменных из d с последующим построением линейного классификатора в d' -мерном подпространстве, не может превосходить $C_d^{d'} C(d')$.

Заметим, что при $N \gg d$ первый множитель пренебрежимо мал, по сравнению со вторым, и перебор подпространств не вносит существенного вклада в емкость. Случай $N \approx d$ требует дополнительного исследования.

Если для гиперплоскостей число способов разделения выборки почти для всех выборок одинаково и равно максимальному, то для других классов решающих функций это может быть не так (в частности для алгоритмов сужения признакового пространства). В этих случаях в качестве более точной меры сложности используется так называемая [1] энтропия: $H = E \log_2 C_v$, где C_v – число способов классификации выборки v функциями из Φ .

Моделирование

Для оценки энтропии и эффективной емкости [2,3] алгоритма линейной классификации с выбором признакового подпространства будем моделировать выборки из равномерного распределения в $[0,1]^d \times \{1,2\}$.




Рис. 1. Смещение эмпирического риска в зависимости от относительного объема выборки.

Реализованный алгоритм классификации осуществляет полный перебор всех подпространств размерности d' , в каждом из которых запускается базовый алгоритм классификации.

Усреднением по большому числу (порядка 1000) выборок были непосредственно вычислены оценки энтропии и смещения эмпирического риска.

Таблица 1. Емкостные характеристики и устойчивость различных алгоритмов линейной классификации.

Полный перебор									Нормальное приближение					
d	d'	N	d		d' из d		d'		d	d'	N	d	d' из d	d'
			E	S	E	S	E	S				S	S	S
5	2	5	5.0	0.50	5.0	0.49	4.5	0.43	5	2	5		0.47	0.34
5	2	10	9.6	0.48	8.5	0.43	6.5	0.35	5	2	10	0.39	0.36	0.24
5	2	20	15.0	0.39	11.3	0.32	8.6	0.27	5	2	15	0.30	0.29	0.17
8	2	8	8.0	0.51	7.8	0.49	5.9	0.39	5	2	20	0.23	0.25	0.14
20	2	20			20.0	0.39	8.6	0.26	10	2	10		0.41	0.19
20	2	100			28.9	0.20	13.3	0.13	20	2	20		0.36	0.13
5	3	5	5.0	0.50	5.0	0.49	4.9	0.48	5	3	10	0.39	0.39	0.27
5	3	10	9.6	0.48	9.2	0.47	8.0	0.41	5	3	15	0.30	0.30	0.21
5	3	20	15.0	0.39	13.5	0.37	11.2	0.32	5	3	20	0.23	0.28	0.17

В таблице 1 приведены полученные значения энтропии (E) и смещения эмпирического риска (S) для линейного классификатора, построенного в исходном пространстве размерности d , для классификатора в наилучшем подпространстве размерности d' и случайном подпространстве размерности d' . Левая часть таблицы соответствует базовому алгоритму, осуществляющему полный перебор гиперплоскостей в выбранном подпространстве, правая – построению разделяющей гиперплоскости в нормальном приближении.

Полученные результаты позволяют сделать вывод о том, что процедура выбора наилучшего подпространства переменных вносит, вообще говоря, существенный вклад в полную емкость алгоритма классификации, и этот вклад тем существеннее, чем меньше эффективная емкость базового алгоритма классификации.

Литература

1. Вапник В. Н., Червоненкис А. Я. Теория распознавания образов. // М.: Наука, 1974. 415 с.
2. Неделько В. М. Оценка смещения эмпирической оценки риска решающей функции. // Доклады Всероссийской конференции «Математические методы распознавания образов», ММРО – 11 Изд-во ВЦ РАН, Москва, 2003. С. 148-150.
3. V. M. Nedelko. Decision Tree Capacity and Probability of Misclassification // LNAI 3505. Autonomous Intelligent Systems: Agents and Data Mining. AIS-ADM 2005. Springer-Verlag, Berlin. pp. 193–199.

Исследование структуры фазового пространства динамической системы как задача распознавания образов

Ю.И. Неймарк, И.В. Котельников, Л.Г. Теклина

(Нижний Новгород)

Введение

Теория динамических систем и дифференциальных уравнений является основой современной науки, а исследование динамических систем – это один из путей познания окружающего нас мира и совершенствования современной техники. Теория динамических систем, возникшая в трудах великих ученых А.Пуанкаре и Д.Биркгофа, получила мощное развитие, однако успехи ее в исследовании конкретных динамических систем достаточно скромны. Еще в тридцатых годах прошлого века академик А.Андронов обратил внимание на недостаточность классической теории динамических систем для исследования реальных систем размерности $n > 2$. Конечно, с того времени математическая теория динамических систем существенно расширилась, но ее возможности по-прежнему отстают от современных потребностей, а несомненные успехи в основном связаны с использованием быстродействующих ЭВМ, что привело к замене $n > 2$ на $n > 3$. Так что и сегодня остаются актуальными слова А.Андропова: «...необходимо отыскать аппарат, который бы адекватно отображал процессы и который был бы, кроме того, достаточно эффективен, т.е. давал бы ответы на вопросы, выдвигаемые физикой и техникой». Для преодоления «проклятия размерности» (по выражению известного ученого Р.Белмана) в исследовании конкретных динамических систем предлагается использовать методы теории распознавания образов,

представляющей собой одну из перспективных направлений в развитии информационных технологий, связанных с извлечением знаний из рассмотрения множества фактических данных.

Компьютерная концепция исследования конкретных динамических систем

Теория динамических систем изучает идеальную математическую модель, выясняя каковы ее возможные фазовые портреты, движения и бифуркации. Однако, требования физики и техники напрямую относятся не к идеальной математической модели динамической системы, а к реальной и вычислимой. А вычислимость даже для конкретных фазовых траекторий не всегда имеет место. При физической реализации динамической системы этому факту отвечает неповторяемость, и можно лишь попытаться найти статистическое описание. Кроме того, практически невычислимыми могут оказаться и некоторые особенности фазового портрета идеальной динамической системы. Но то, что не вычислимо, как нам представляется, не может быть физически или технически значимым. Следует при этом различать принципиальную и реальную вычислимости. Так, экспоненциально неустойчивая траектория принципиально вычислима для любого конечного промежутка времени, а реально – только для времени, меньше некоторого T_0 . Возможность численного исследования конкретных динамических систем ограничена реальной вычислимостью.

В основу предлагаемой компьютерной концепции исследования конкретных динамических систем положены реализуемые вычисления, необходимые ограничения и исходные данные. Фазовое пространство предполагается конечным, оператор динамической системы вычислимым, понятия устойчивости и неустойчивости уточнены, определены понятия малых и больших пространственных и временных величин, аттракторов и их областей притяжения, конечная цель вычислений. При этом следует вычислительно различать, когда аттрактор есть устойчивое равновесие или периодическое движение и когда это хаотический аттрактор.

Целью вычислений является получение не достоверных результатов, а статистически достоверных с вероятностью $p < 1$, но определенно близкой к единице. Результатом компьютерного исследования динамической системы является определение структуры фазового пространства в виде некоторого множества аттракторов J_S и их областей притяжения $O(J_S)$, а также разделяющих их границ. Все это в пределах определяемых точностей и времени, которые при необходимости могут быть уточнены и расширены.

Следует особо подчеркнуть, что достоверность полученных

результатов не зависит от размерности динамической системы, а определяется объемом проведенных вычислений.

Построение компьютерной структуры фазового пространства методами распознавания образов

Практическое построение компьютерного фазового портрета для конкретной динамической системы основывается на определенном образом вычисляемом массиве конечных отрезков фазовых траекторий в прямом и обратном временах, рассматриваемом как обучающее множество данных, и на понятиях их устойчивости и неустойчивости, представляющих собой основу для задания функции учителя на этом обучающем множестве.

Для построения компьютерной структуры фазового пространства динамической системы необходимо решить три основные задачи:

- 1) Определение вида фазовой траектории. Для диссипативных систем это – траектории, стремящиеся к состоянию равновесия, траектории, стремящиеся к предельному циклу, и хаотические и стохастические движения.
- 2) Отыскание предельных устойчивых подмножеств фазового пространства (аттракторов).
- 3) Выделение областей притяжения аттракторов.

Каждая из трех поставленных задач может быть решена методами теории распознавания образов. Выбор таких методов неоднозначен. Предлагаем краткое описание одного из возможных вариантов решения, опирающегося на методы, обладающие широкими адаптивными возможностями:

- решение задачи распознавания вида фазовой траектории с целью создания обучающей выборки данных Θ , представляющей собой множество отрезков кривых в фазовом пространстве исследуемой динамической системы (конечные многомерные временные ряды) с указанием их типа;
- кластерный анализ данных из обучающей выборки Θ и построение локальных решающих правил для отыскания аттракторов;
- решение задачи распознавания областей притяжения для выделенных устойчивых подмножеств (аттракторов) путем построения разделяющих решающих правил на основе множества Θ .

Вторая и третья задачи решаются на основе обучающей выборки данных Θ для конкретной исследуемой динамической системы, создаваемой в процессе *активного* эксперимента и с использованием решающего правила распознавания типа фазовых траекторий. Такое правило строится на базе признаков, формируемых методами распознавания образов. Для первоначального описания используются как

координаты траекторий в фазовом пространстве для последовательных моментов времени, так и известные из теории динамических систем особенности поведения траекторий различного типа при $t \rightarrow \infty$. Для выделения множества признаков, информативных для решения поставленной задачи распознавания, проводится анализ расширенной обучающей выборки, состоящей из отрезков фазовых траекторий известного вида для различных и по своей природе, и по размерности динамических систем. Для такого анализа могут быть применены, в частности, такие математические инструменты, как построение синдромов и авторегрессия.

Заключение

Предлагаемый доклад имеет целью показать, что проблема исследования конкретных динамических систем может естественно и плодотворно рассматриваться как задача распознавания образов и что на этом пути возможно существенное продвижение в ее решении. Такая постановка задачи не подменяет существующую обширную и мощную теорию динамических систем, а на ней основывается и ее использует.

Работа выполнена при частичной финансовой поддержке РФФИ (проект № 05-01-00391).

Авторегрессионный анализ фазовых траекторий динамических систем

Ю.И. Неймарк, Л.Г. Теклина

(Нижний Новгород)

Качественное исследование динамических систем, заданных системами дифференциальных уравнений достаточно высокого порядка, – это математическая проблема с выходом на аналитические и числовые результаты, имеющие большое практическое значение для физики и техники. В настоящее время исследование конкретной динамической системы порядка $n \geq 3$ требует нестандартного подхода и основывается на интуиции исследователя и скрупулезном анализе особенностей рассматриваемой системы. Для формализации, а в конечном счете и автоматизации процесса исследования динамических систем предлагается новый подход, основанный на решении задачи построения фазового портрета динамической системы методами распознавания образов путем извлечения знаний из рассмотрения фактических данных, получаемых в ходе активного эксперимента [1].

Реализация нового подхода невозможна без решения задачи распознавания различных типов фазовых траекторий динамических систем. Для диссипативных систем это – траектории, стремящиеся к устойчивому состоянию равновесия, траектории, стремящиеся к

предельному циклу, и хаотические и стохастические движения. Построение решающего правила требует выделения множества признаков, информативных для решения поставленной задачи распознавания. С целью выбора таких признаков и был проведен анализ фазовых траекторий для разных и по своей природе, и по размерности динамических систем. Для этого была взята обучающая выборка \mathbf{X} , состоящая из отрезков фазовых траекторий – кривых, представляющих собой решения K различных систем дифференциальных уравнений порядка n_k . Траектории заданы значениями своих координат в фазовом пространстве размерности n_k в последовательные моменты времени с постоянным для данной кривой шагом дискретизации Δt . Некоторые кривые представлены в выборке несколькими отрезками, характеризующими особенности поведения траектории и в переходные моменты, и при $t \rightarrow \infty$. Таким образом, обучающая выборка \mathbf{X} - это множество конечных многомерных временных рядов разной размерности и длительности:

$$\mathbf{X} = \left\{ \mathbf{x}^{ik} / i = 1, \dots, N_k, k = 1, \dots, K \right\},$$

где $\mathbf{x}^{ik} = (x_{j1}^{ik}, x_{j2}^{ik}, \dots, x_{jn_k}^{ik})$, $j = 1, \dots, M_{ik}$ и $\sum_{k=1}^K N_k = N$.

Из всего множества существующих методов анализа многомерных временных рядов для формирования признаков с целью распознавания типа фазовых траекторий, которые, по определению, различаются своим поведением при $t \rightarrow \infty$, была выбрана авторегрессия, во-первых, как наиболее известный, доступный и эффективный способ обнаружения закономерностей следования значений временного ряда и, во-вторых, как аппарат, успешно реализуемый с использованием универсальной рекуррентной формы метода наименьших квадратов [2], обладающей широкими адаптивными возможностями. Применение последней позволило не только быстро обрабатывать временные ряды любой длительности, но и проводить анализ в адаптивном режиме, когда каждое последующее действие определяется результатами предыдущего.

Для исследования возможностей описания поведения траекторий \mathbf{x}^V в фазовом пространстве динамической системы при $t \rightarrow \infty$ с помощью авторегрессионных функций были рассмотрены несколько авторегрессионных моделей и выбрана *линейная модель «скользящей» авторегрессии* (с анализом последовательности пересекающихся интервалов) *порядка* $p = 5$ для одномерных временных рядов \mathbf{y}^V , представляющих собой изменение со временем расстояний между

соседними точками исходного временного ряда \mathbf{x}^v , $v = 1, 2, \dots, N$, т.е.

$$\mathbf{y}^v = (y_1^v, y_2^v, \dots, y_{M_v-1}^v), \quad \text{где} \quad y_l^v = \sqrt{\sum_{j=1}^{n_k} (x_{lj}^v - x_{l+1,j}^v)^2}.$$

В качестве основных параметров модели – признаков для решения в последующем задачи распознавания – использовались линейные коэффициенты авторегрессии $\mathbf{a}(t)$ и корни $q(t)$ соответствующего характеристического полинома.

Исследование поведения фазовых траекторий с помощью предложенной авторегрессионной модели дало следующие основные результаты:

1) Выявлен закономерный характер изменений в динамике коэффициентов авторегрессии и корней характеристического полинома для различного типа траекторий: для траекторий, стремящихся к состоянию равновесия, функции $|a(t)|$ и $|q(t)|$ с некоторого момента времени монотонно убывают вплоть до исчезновения авторегрессионной составляющей; для траекторий, стремящихся к предельному циклу, параметры авторегрессии приближаются к некоторому определенному установившемуся значению, а максимальный по модулю корень стремится и остается равным 1 при соответствующем выборе интервала скольжения; для хаотических и стохастических движений имеет место хаотическое изменение параметров во времени, а некоторые из корней характеристического уравнения отвечают неравенству $|q(t)| > 1$.

Сказанное можно проиллюстрировать рис.1, где приведены графики характерного изменения со временем лишь одного из параметров для предельных периодических движений (жирная линия), хаоса (тонкая линия) и устойчивых состояний равновесия (пунктирная линия) двух динамических систем.

2) Показана возможность отыскания периодических движений и расчета периода с помощью выбора соответствующего анализируемого интервала скольжения.

3) Оказалось, что по характеру изменения коэффициентов авторегрессии и корней характеристического полинома во времени для хаотических и стохастических движений все множество кривых разделяется на конечное число сходных между собой подмножеств, что предполагает в дальнейшем возможность классификации хаотических движений.

Работа выполнена при частичной финансовой поддержке РФФИ (проект №05-01-00391).




Рис. 1.

Литература

1. Неймарк Ю.И., Котельников И.В., Теклина Л.Г. Исследование структуры фазового пространства динамической системы как задача распознавания образов // Доклад в данном сборнике, 2005. С.
2. Неймарк Ю.И., Теклина Л.Г. Новые технологии применения метода наименьших квадратов. Учебное пособие. Нижний Новгород. Изд. Нижегородского государственного университета, 2003.

Параметризация рукописных слов и траектории движения пера при анализе сканированных рукописных документов

А.Г. Нефедов

(Тверь)

Контейнеры штрихов

В основе подхода лежит модель рукописного слова, описанная в [1].




Рис. 1

Пусть G – скелетный граф. s_1, \dots, s_n – ветви скелетного графа, s_1, \dots, s_k , $k < n$ однопроходные ветви. v_1, \dots, v_r – вершины скелетного графа.

Пусть g_1, \dots, g_m – множество штрихов (подграфов). Например, штрих может быть получен как $s_1 \cup s_2$ или $s_4 \cup s_6$.

Рассмотрим множество G'_i всех возможных штрихов g_1, \dots, g_l , $l < m$, включающих ветвь s_i , т.е. для которых выполняется условие $s_i \in g_j$, $j = 1, \dots, l$. G'_i – образует **пучок штрихов** для s_i .

На множестве пучков введем отношение смежности. Два пучка штрихов G' и G'' называются смежными, если $\forall g' \in G', \exists g'' \in G''$ имеет место $g' \cap g'' \neq \emptyset$.

Отношение смежности задается на множестве пучков графом. Максимальное по включению множество попарно смежных пучков, называется **контейнером**. Множество контейнеров $U = \{U_1, \dots, U_h\}$, однозначно задает разбиение скелетного графа G на непересекающиеся подграфы. Каждому контейнеру можно поставить в соответствие порядковый номер $1 \leq r \leq h$, причем для всех i, j таких, что $1 \leq i, j \leq h, i \neq j$ имеем $U_i \cap U_j = \emptyset$.

В примере на рис.2 для ветви скелета s_1 , построен пучок штрихов $G_1 = \{g_1^1, g_2^1, g_3^1\}$, а для s_2 пучок $G_2 = \{g_1^2, g_2^2, g_3^2\}$. Пучки G_1 и G_2 являются смежными. На рисунке штрихи показаны темным цветом. Также, для s_3 построен пучок $G_3 = \{g_1^3, g_2^3\}$, а для s_4 – пучок $G_4 = \{g_1^3, g_2^3\}$. Пучки G_3 и G_4 являются смежными. Пучки для s_5, s_6, s_7 не рассматриваются, так как эти ветви скелетного графа не образуют новых штрихов. Отметим, что никакие другие пучки, кроме указанных, не являются попарно смежными. Таким образом, пучки G_1 и G_2 образуют **контейнер** $U_1 = \{g_1^1, g_2^1, g_3^1, g_2^2, g_3^2\}$, а пучки G_3 и G_4 **контейнер** $U_2 = \{g_1^3, g_2^3, g_1^4\}$.

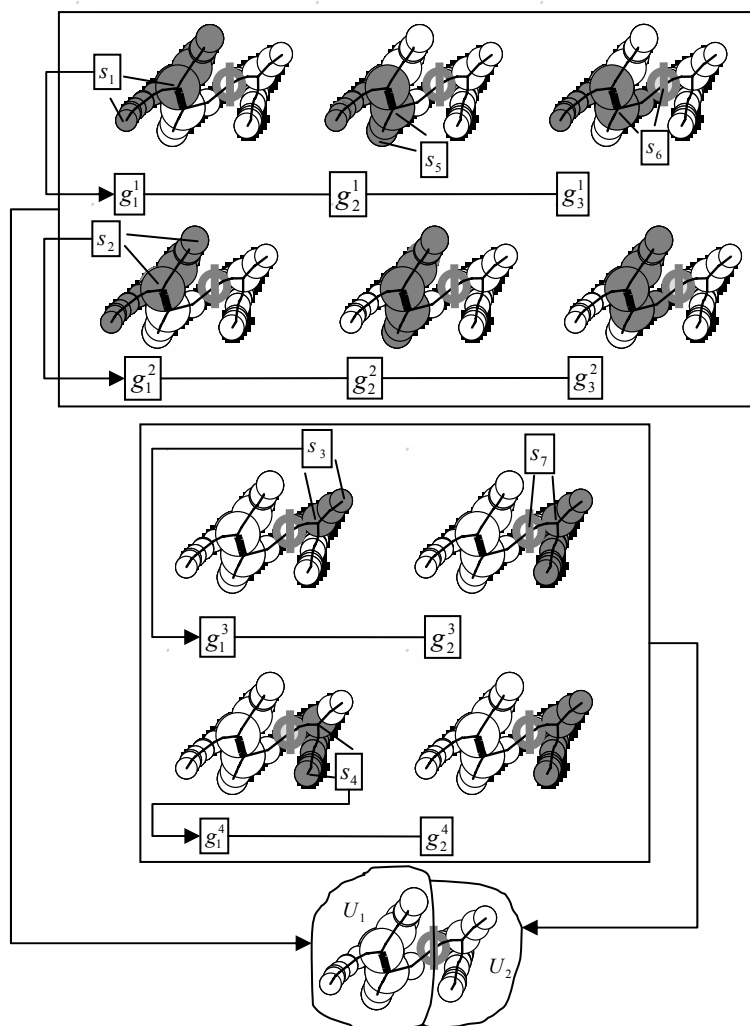


Рис. 2 Разбиение рукописного слова на контейнеры.

Параметризация рукописных слов и траектории движения

Пусть для изображения рукописного слова построен граф G , а также его разбиение U на контейнеры. Каждое $U_r \in U$ представляет собой последовательность штрихов $\{g_1, \dots, g_{m_r}\}$, где m_r – количество штрихов в r -том контейнере. Таким образом, любой штрих g_{i_r} однозначно

определяется номером контейнера r и номером $1 \leq i \leq m_r$ в последовательности штрихов контейнера. Для каждого штриха может быть задано направление движения по штриху $z_{i,r} = \pm 1$ в зависимости от терминальной вершины, с которой начинается движение по штриху.

Следовательно, для известного скелетного графа G и его разбиения U траектория движения пера может быть задана параметрически последовательностью штрихов

$T = \{\{r, i, z\}_1, \dots, \{r, i, z\}_p\}$, $1 \leq r \leq h$; $1 \leq i \leq m_r$; $z = \pm 1$, где h – количество контейнеров, p – количество штрихов в траектории. Если такая последовательность известна, то для скелетного графа G и его разбиения U на подграфы (контейнеры), можно однозначно восстановить траекторию движения пера.

Заключение

Предлагаемая формальная модель, является основой, для формирования и оценки гипотез о структуре следа пера и эффективности применяемых алгоритмов. Работа выполнена при поддержке РФФИ (грант номер 05-01-00542).

Литература

1. Нефедов А. Классификация сложных сопряжений штрихов при анализе рукописных документов // Труды 7-ой Международной конференции распознавания образов и анализа изображений. Санкт-Петербург, 2004.

Об информационной технологии спектрального анализа высокого разрешения

А.Н. Панкратов

(Пушино)

Актуальной является проблема увеличения разрешающей способности алгоритмов получения частотного спектра для сложных нестационарных сигналов, относящихся к разного рода переходным процессам или стохастическим системам. Такие проблемы возникают в современных методах исследования таких, как импульсные методики ядерного магнитного резонанса, задачах анализа акустических сигналов.

В современной практике получения частотного спектра в основном используется быстрое преобразование Фурье (БПФ) в сочетании с оконными преобразованиями (выравниваниями) сигналов. Поэтому основная задача состоит в построении и исследовании альтернативных по отношению к БПФ методов и алгоритмов получения частотного спектра для разных классов нестационарных сигналов. Внедрение так называемого

кратномасштабного описания сигналов (вейвлет – преобразований) породило новую концепцию частотно-временного анализа сигналов. Однако, это не отменило классический Фурье-анализ, более того, сравнение результатов Фурье и вейвлет-анализа практически невозможно. Это связано с тем, что в дискретных системах типа Хаара частоты связаны геометрической, а не арифметической прогрессией, как в классической ортогональной системе тригонометрических полиномов Фурье. Такова плата за возможность локализованного описания особенностей сигналов при вейвлет-анализе. Применение функций Лагерра и Эрмита для описания сигналов и последующего аналитического преобразования спектра позволяет сравнивать результаты с Фурье анализом. Это связано с тем, что интеграл Фурье от функций Лагерра и Эрмита выражается аналитически. Фактически, в случае разложения по функциям Эрмита и Лагерра частотный спектр получается с помощью интегрального, а не дискретного преобразования Фурье. Результаты непрерывного и дискретного преобразований Фурье сравнимы, а исходные данные принадлежат разным классам функций: интегрируемых с квадратом на всей числовой оси, то есть экспоненциально затухающих (для интеграла Фурье), или периодических (для БПФ).

Работа выполняется при поддержке Фонда содействия отечественной науке и проектов РФФИ № 04-02-17368, № 04-01-00756.

Литература

1. Классические ортогональные базисы в задачах аналитического описания и обработки информационных сигналов: Учебное пособие/ Ф.Ф.Дедус, Л.И.Куликова, А.Н.Панкратов, Р.К.Тетуев. Под ред. Ф.Ф.Дедуса. - М.: Издательский отдел Факультета ВМиК МГУ им. М.В.Ломоносова, 2004

Применение алгоритмов параллельных вычислений для решения задач дискретной оптимизации и распознавания

М.А. Посыпкин, И.Х. Сигал

(Москва)

В ряде случаев при построении процедур распознавания и кластеризации может быть использован аппарат дискретного программирования (дискретной оптимизации). Например, разного вида задачи поиска покрытий булевой и целочисленной матриц возникают при синтезе элементарных классификаторов в логических процедурах распознавания [1]. В частности, задача поиска минимальных покрытий булевой матрицы актуальны при построении логического корректора на базе элементарных классификаторов [2].

Еще одним примером являются алгоритмы распознавания, основанные на вычислении оценок [3]. Степень их корректности зависит от выбора

параметров, характеризующих представительность каждого из обучающих объектов и каждого из опорных множеств. Задача сводится к решению систем линейных неравенств и, если система несовместна, то к выбору ее максимальной совместной подсистемы, что в свою очередь эквивалентно максимизации суммы булевых переменных в которой, i -ая переменная равна 1 если i -ое неравенство верно и 0 в противном случае.

После выбора подходящей функции критерия качества классификации задача кластерного анализа становится корректно поставленной задачей дискретной оптимизации: найти такие разбиения множества классифицируемых объектов, которые приводят к минимуму (максимуму) функции критерия качества [4].

Численное решение задач дискретной оптимизации может представлять значительные сложности. Для решения этих задач применяются, как правило, комбинаторные методы. При этом метод «ветвей и границ» [5,6] и различные его модификации применяются наиболее часто и относятся к числу основных при решении задач дискретного программирования. Решение задач большой размерности [7] на последовательных вычислительных машинах может потребовать существенных вычислительных ресурсов (время, память), что связано с перебором большого числа вариантов. Как было показано в работе [5] для задачи о ранце с n булевыми переменными этот перебор может оказаться близким к полному и иметь порядок $2^n / \sqrt{n}$. Отсюда, естественным образом, возникает задача применения параллельных методов [8] для ускорения процесса решения.

Для решения поставленной задачи нами была разработана объектно-ориентированная библиотека BNBSolver [9], предназначенная для распараллеливания метода «ветвей и границ». Механизм шаблонов, применяемый в библиотеке, позволяет интегрировать между собой различные стратегии ветвления, методы распределения работы между процессорами и алгоритмы решения конкретных задач дискретной оптимизации. На данный момент из методов распараллеливания в библиотеке реализованы метод назначаемых поддеревьев [10] и схема «управляющий-работчие» с упорядоченной очередью заданий [11]. Написаны прикладные модули для решения задач о ранце с одним и многими ограничениями.

Проведенные вычислительные эксперименты показали высокие эффективность и масштабируемость, которые удается достичь с помощью применения библиотеки. На рис. 1 представлен график зависимости времени решения задачи об одномерном булевом ранце от числа процессоров в решающем поле, демонстрирующий высокую масштабируемость алгоритма. Входные данные взяты из монографии [1]:

$$\sum_{i=1}^n 2x_i \rightarrow \max, \sum_{i=1}^n 2x_i \leq 2 \left\lceil \frac{n}{2} \right\rceil + 1, n \geq 4, x_i \in \{0,1\}, i = 1,2,\dots,n$$

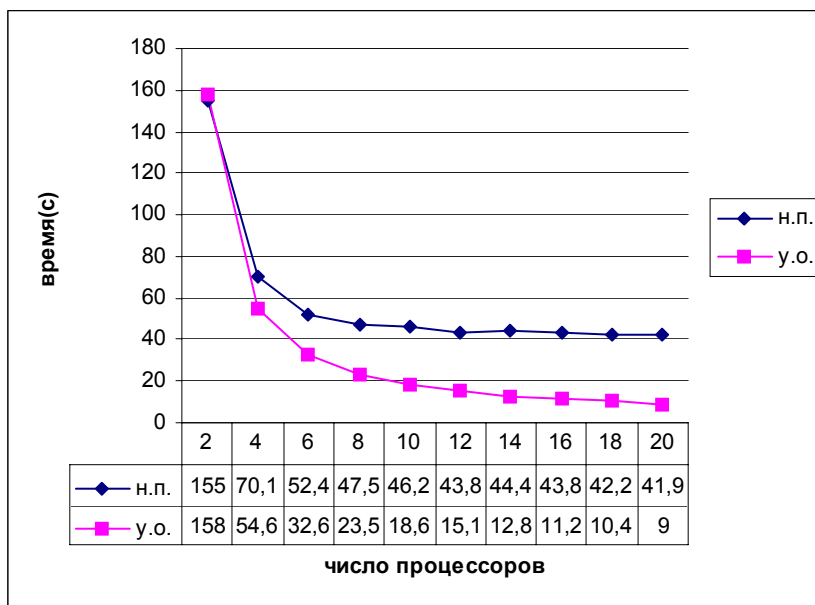


Рисунок 1

Вычислительные эксперименты проводились на многопроцессорном вычислительном комплексе MVS-15000BM, установленном в Межведомственном суперкомпьютерном центре РАН (МСЦ РАН).

В дальнейшем планируется совершенствование методов распараллеливания, применяемых в библиотеке BNBSolver, а также расширение спектра прикладных задач, решаемых с ее помощью. В частности, перспективным направлением является разработка модулей для задач распознавания, решение которых сводится к решению задач дискретной оптимизации.

Работа выполнена при поддержке проекта РФФИ № 05-01-00495.

Литература

1. 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.
2. Дюкова Е.В., Журавлев Ю.М., Рудаков К.В. Об алгебро-логическом синтезе корректных процедур распознавания на базе элементарных алгоритмов // Ж. вычисл. матем. и матем. физ. 1996. Т. 36, 1 8. С. 217-225.

3. Журавлёв Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Пробл. кибернетики. М.: Наука, 1978. Вып. 33. С. 5-68.
4. Дуда Р. О., Харт П. Е. Распознавание образов и анализ сцен // «Мир» Москва 1976.
5. Финкельштейн Ю.Ю. Приближенные методы и прикладные задачи дискретного программирования // М.: Наука, 1976.
6. Сигал И.Х., Иванова А.П. Введение в прикладное дискретное программирование // М.: Физматлит, 2002.
7. Сигал И.Х. Параметризация и исследование некоторых задач дискретного программирования большой размерности // Известия РАН. Теория и системы управления. 2001. №2, С. 83-92.
8. Воеводин В.В., Воеводин Вл. В. Параллельные вычисления // СПб.: БХВ-Петербург, 2002.
9. Посыпкин М.А., Сигал И.Х., Галимьянова Н.Н. Алгоритмы параллельных вычислений для решения некоторых классов задач дискретной оптимизации // препринт ВЦРАН, 2005.
10. Тимошевская Н.Е. Параллельные методы обхода дерева // Математическое моделирование, 16(4), 2004.
11. Grama A., Gupta A., Karypis G., Kumar V., Introduction to parallel computing, Addison-Wesley, 2003.

Выбор функции расстояния при сравнении фазовых траекторий

Г.О. Пташко, В.В. Стрижов, В.В. Шакин

(Москва)

При решении задач медицинской диагностики возникает проблема сравнения фазовых траекторий истории болезни пациентов. Предполагается, что пациенты с одинаковым диагнозом имеют сходные траектории [1]. Требуется найти функцию расстояния между траекториями, которая бы удовлетворяла внешнему критерию, задаваемому экспертом. С помощью этой функции создается матрица парных расстояний между траекториями для последующей классификации пациентов по типам болезней.

Задано X – множество многомерных временных рядов $\{X_1, \dots, X_N\}$, где $X_i = \langle X_i^{(1)}, \dots, X_i^{(n_i)} \rangle$ – вектор длины n_i и C – внешний критерий качества классификации, заданный экспертом. Требуется найти такую функцию ρ , которая бы давала наилучшую классификацию кривых из X , минимизирующую критерий $C(\rho_{ij})$. Аргументы функции

$\rho(w(X_i, X_j), \varphi)$ – путь минимальной стоимости w , определенный двумя временными рядами, и модельная кривая φ из заданного класса кривых B , приближающая w .

Рассмотрим временные ряды X_i и X_j из множества X . Найдем расстояния μ между всеми парами элементов этих рядов. Элемент матрицы $A = \{a_{kl}\}_{k,l=1}^{m,n}$ равен расстоянию между парой элементов временных рядов X_i и X_j , то есть $a_{kl} = \mu(X_i^{(k)}, X_j^{(l)})$. Путь $w = \{w_l\}$ длины K в матрице A есть последовательность элементов $\{w_l\}$, $l = \overline{1, K}$ таких, что $w_1 = a_{11}$, $w_K = a_{mn}$, а для $w_l = a_{ij}$ элемент $w_{l+1} = a_{i+\xi, j+\zeta}$, $\xi + \zeta \in \{1, 2\}$. Назовем стоимостью пути число $P(w) = \frac{1}{K} \sum_{l=1}^K w_l$. Определим функцию расстояния между двумя временными рядами DTW (*Dynamic Time Warping* [2]), как минимальную стоимость пути w , то есть $DTW(X_1, X_2) = \min_w \{P(w)\}$. Аппроксимируем путь минимальной стоимости w модельной кривой $\varphi \in B$. Выберем такую φ , которая минимизирует функционал $C(\rho_{ij})$ для всех данных временных рядов X .

Предложенный метод протестирован на историях болезни пациентов гематологического центра РАМН.

Данная работа поддержана грантом РФФИ 04-01-00401-а.

Литература

1. Shakin V., Ptashko G. et. al. Decision support system using multimedia case history: quantitative comparison and multivariate statistical analysis // IEEE CBMS 2005 proceedings. Dublin, 2005. pp. 128-133.
2. Selina Chu, Eammon Keogh, David Hart, and Michael Pazzani. Iterative Deepening Dynamic Time Warping for Time Series // Proceedings of the Second SIAM International Conference on Data Mining. 2002

Вероятность и возможность. Эмпирическая интерпретация и оценивание

Ю.П. Пытьев

(Москва)

Обозначим $(\Omega, \mathcal{P}(\Omega), Pr)$ вероятностное пространство (В.П.), моделирующее стохастический эксперимент \mathfrak{E} , $\Omega = \{\omega_1, \omega_2, \dots\}$ — множество элементарных исходов \mathfrak{E} , $\mathcal{P}(\Omega)$ — класс всех подмножеств Ω , представляющих все исходы \mathfrak{E} , $Pr(\cdot) : \mathcal{P}(\Omega) \rightarrow [0, 1]$ — вероятность, определенную равенством

$$Pr(A) = \sum_{i: \omega_i \in A} pr_i, \quad A \in \mathcal{P}(\Omega), \quad \text{где } pr_i \stackrel{\text{def}}{=} Pr(\{\omega_i\}), \quad i = 1, 2, \dots, —$$

распределение $Pr(\cdot)$. Если $(\Omega, \mathcal{P}(\Omega), Pr)^n = (\Omega^n, \mathcal{P}(\Omega^n), Pr^n)$ — модель \mathfrak{E}^n — n раз взаимно независимо повторенного \mathfrak{E} , где $Pr^n = Pr \times \dots \times Pr$, и $v^{(n)}(A)$ — частота исхода A в \mathfrak{E}^n , то при $n \rightarrow \infty$ почти наверное $v^{(n)}(A) \rightarrow Pr(A)$, точнее

$$\forall A \in \mathcal{P}(\Omega) \forall \varepsilon > 0 \lim_{n \rightarrow \infty} Pr^\infty \left(\sup_{k \geq n} |v^{(k)}(A) - Pr(A)| > \varepsilon \right) = 0. \quad (1)$$

Усиленный З.Б.Ч. (1) определяет событийно-частотную интерпретацию Pr : с увеличением n $v^{(n)}(A)$ приближается и в смысле (1) остается близкой к $Pr(A)$, т.е. — эмпирически оценивает Pr .

Теоретико-возможностной (нечеткой) моделью \mathfrak{E} является пространство с возможностью $(\Omega, \mathcal{P}(\Omega), P)$, в котором возможность $P(\cdot) : \mathcal{P}(\Omega) \rightarrow [0, 1]$, как и вероятность $Pr(\cdot) : \mathcal{P}(\Omega) \rightarrow [0, 1]$, является мерой, значение $P(A)$ которой оценивает шанс любого исхода $A \in \mathcal{P}(\Omega)$ эксперимента по сравнению с шансами любых других его исходов; численные значения $P(\cdot)$ не важны, имеет смысл лишь их упорядоченность [1].

Пусть распределение Pr упорядочено по невозрастанию

$$1 \geq pr_1 \geq pr_2 \geq \dots \geq 0, \quad pr_1 + pr_2 + \dots = 1, \quad (2)$$

Pr — класс всех таких вероятностей. Тогда при *любом* определении возможности P ее распределение $p_i = P(\{\omega_i\}), i = 1, 2, \dots$ должно быть упорядочено аналогично:

$$1 = p_1 \geq p_2 \geq \dots \geq 0. \quad (3)$$

Класс всех таких возможностей обозначим \mathbf{P} .

Рассмотрим вариант возможности, определенной равенством [1]
 $P(A) = \sup_{i: \omega_i \in A} p_i, A \in \mathcal{P}(\Omega)$. Возможности P и P' назовем

эквивалентными, если $\exists \gamma(\cdot) \in \Gamma \forall A \in \mathcal{P}(\Omega) P(A) = \gamma(P'(A))$, Γ — группа непрерывных строго монотонных преобразований $\gamma(\cdot): [0,1] \rightarrow [0,1], \gamma(0) = 0, \gamma(1) = 1$.

Класс \mathbf{P} представим как объединение непересекающихся неприводимых классов $\mathbf{P}_{(e)}, e \in (0,1]$, эквивалентных возможностей $\mathbf{P} = \bigcup_{e \in (0,1]} \mathbf{P}_{(e)}$, где $e = 0.e_1e_2\dots$ — двоичная запись числа из $[0,1]$, определяющего упорядоченность распределения возможности $P \in \mathbf{P}_{(e)}$ согласно условиям $p_i = p_{i+1} \Leftrightarrow e_i = 0, p_i > p_{i+1} \Leftrightarrow e_i = 1, i = 1, 2, \dots$

P назовем согласованной с Pr , $Pr \sim > P$, если $\exists \tilde{\gamma}(\cdot) \in \tilde{\Gamma} \forall A \in \mathcal{P}(\Omega) P(A) = \tilde{\gamma}(Pr(A))$, где $\tilde{\Gamma}$ — класс монотонно неубывающих функций $\tilde{\gamma}(\cdot): [0,1] \rightarrow [0,1], \tilde{\gamma}(0) = 0, \tilde{\gamma}(1) = 1$. P максимально согласована с Pr , $Pr \approx > P$, если $Pr \sim > P$ и $\forall \tilde{P}, Pr \sim > \tilde{P}, \exists \tilde{\gamma}(\cdot) \in \tilde{\Gamma} \forall A \in \mathcal{P}(\Omega) \tilde{P}(A) = \tilde{\gamma}(P(A)) \stackrel{def}{=} \tilde{\gamma} * P(A)$. $Pr \approx > P$, если и только если распределения в (2) и (3) связаны условиями [2]

$$\begin{aligned} e_i = 1 &\Leftrightarrow p_i > p_{i+1} \Leftrightarrow \overset{def}{f_i} = pr_1 + \dots + pr_{i-1} + 2pr_i > 1, \\ e_i = 0 &\Leftrightarrow p_i = p_{i+1} \Leftrightarrow f_i \leq 1, i = 1, 2, \dots \end{aligned} \quad (4)$$

Сопоставим разбиению класса \mathbf{P} разбиение $\mathbf{Pr} = \bigcup_{e \in (0,1]} \mathbf{Pr}_{(e)}$, в котором класс $\mathbf{Pr}_{(e)}$ сопоставлен классу $\mathbf{P}_{(e)}$, причем так, что любая возможность $P \in \mathbf{P}_{(e)}$ максимально согласована со всеми вероятностями $Pr \in \mathbf{Pr}_{(e)}$ и только с ними. Разбиения классов \mathbf{P}, \mathbf{Pr} и эквивалентности (4) сводят задачу эмпирического определения возможности к задаче проверки статистических гипотез о значениях $f_i, i = 1, 2, \dots$, в (4).

Стохастической моделью последовательности n независимых испытаний, в которых вероятность произвольно изменяется от испытания к испытанию, является В.П.

$(\Omega \times \dots \times \Omega, \sigma(F \times \dots \times F), Pr_1 \times \dots \times Pr_n)$. В этом случае усиленный 3.Б.Ч. (1) означает, что

$$\forall \varepsilon > 0 \lim_{N \rightarrow \infty} Pr^\infty \left(\sup_{n \geq N} |v^{(n)}(A) - \frac{1}{n} \sum_{i=1}^n Pr_i(A)| > \varepsilon \right) = 0. \quad (5)$$

Пусть среди вероятностей Pr_1, Pr_2, \dots конечное число k различных, скажем, Pr^1, \dots, Pr^k . Тогда

$$\frac{1}{n} \sum_{i=1}^n Pr_i(A) = \sum_{s=1}^k (n_s/n) Pr^s(A) \stackrel{def}{=} Pr_{(n)}(A), \quad A \in F, \quad (6)$$

где n_s/n — частота, с которой вероятность Pr^s встречается в последовательности Pr_1, \dots, Pr_n , $s = 1, \dots, k$. Поскольку с увеличением n частоты n_s/n , $s = 1, \dots, k$, изменяются, вообще говоря, произвольно, значение $Pr_{(n)}(A)$ в (6) произвольно «блуждает» по отрезку $[\min_{1 \leq s \leq k} Pr^s(A), \max_{1 \leq s \leq k} Pr^s(A)]$, и согласно (5) при $n \rightarrow \infty$ за ним все более

точно следует частота $v^{(n)}(A) = \sum_{s=1}^k (n_s/n) v^{(n_s)}(A)$, где $v^{(n_s)}(A)$ — частота исхода A в подпоследовательности испытаний, контролируемой вероятностью Pr^s , причем согласно усиленному 3.Б.Ч. (5) при $n \rightarrow \infty$ $v^{(n_s)}(A) \xrightarrow{п.н.} Pr^s(A)$, $s = 1, \dots, k$.

В этом случае знание вероятностей $Pr^1(A), \dots, Pr^k(A)$ не позволяет оценить частоту $v^{(n)}(A)$, а наблюдение за $v^{(n)}(A)$, $n = 1, 2, \dots$, не позволяет восстановить стохастическую модель наблюдений. Вместе с тем, если вероятности $Pr^1(\cdot), \dots, Pr^k(\cdot)$ таковы, что существует возможность P , максимально согласованная с каждой вероятностью Pr^1, \dots, Pr^k , то при условии регулярности Pr^1, \dots, Pr^k ее можно восстановить п.н. безошибочно на основе конечного числа наблюдений и дать ей событийно-частотную интерпретацию: неравенство $P(A) > P(B)$ означает, что $\exists N(A, B) \forall n \geq N(A, B)$ $v^{(n)}(A) \xrightarrow{п.н.} v^{(n)}(B)$.

Действительно, максимальная согласованность P с Pr^1, \dots, Pr^k означает, что распределения P и Pr^1, \dots, Pr^k удовлетворяют условиям

$$\begin{aligned} p_i > p_{i+1}, &\Leftrightarrow f_i^s \stackrel{def}{=} pr_1^s + \dots + pr_{i-1}^s + 2 pr_i^s > 1, \quad (7) \\ p_i = p_{i+1}, &\Leftrightarrow f_i^s \leq 1, \quad i = 1, 2, \dots, s = 1, \dots, k. \end{aligned}$$

Пусть $Pr_{(n)}(\{\omega_j\}) \stackrel{def}{=} pr_j^{(n)} = \sum_{s=1}^k (n_s/n) pr_j^s$,
 $v^{(n)}(\{\omega_j\}) \stackrel{def}{=} v_j^{(n)} = \sum_{s=1}^k (n_s/n) \cdot v_j^{(n_s)}$, $j = 1, \dots, m$. Так как при $n \rightarrow \infty$ для
 всех $s = 1, \dots, k$ и любого $m = 1, 2, \dots$ $(v_1^{(n_s)}, \dots, v_m^{(n_s)}) \xrightarrow{п.н.} (pr_1^s, \dots, pr_m^s)$, то
 при $n \rightarrow \infty$

$$v_j^{(n)} - pr_j^{(n)} \xrightarrow{п.н.} 0 \Rightarrow \hat{f}_j^{(n)} - f_j^{(n)} \xrightarrow{п.н.} 0, j = 1, 2, \dots, \quad (8)$$

где $f_j^{(n)} \stackrel{def}{=} pr_1^{(n)} + \dots + pr_{j-1}^{(n)} + 2pr_j^{(n)}$, $\hat{f}_j^{(n)} \stackrel{def}{=} v_1^{(n)} + \dots + v_{j-1}^{(n)} + 2v_j^{(n)}$,
 $j = 1, 2, \dots$, и согласно двум альтернативам в (7) для всех $n = 1, 2, \dots$ в (8)
 либо $f_j^{(n)} \leq 1$, либо $f_j^{(n)} > 1$, $j = 1, 2, \dots$

Если выполнено условие регулярности вероятностей Pr^1, \dots, Pr^k , т.е.
 если $\exists M pr_1 \geq pr_2 \geq \dots \geq pr_M > 0 = pr_{M+1} = \dots, f_1^s \neq 1, \dots, f_M^s \neq 1 =$
 $= f_{M+1}^s = \dots, s = 1, \dots, k$, либо $pr_j > 0, f_j^s \neq 1, s = 1, 2, \dots, k, j = 1, 2, \dots$, то
 в силу (8) $\forall m = 1, 2, \dots, M \quad \exists \bar{n} = n(m) \quad \forall n \geq \bar{n}$
 $f_j^{(n)} < 1 (f_j^{(n)} > 1) \xrightarrow{п.н.} \hat{f}_j^{(n)} < 1 (\hat{f}_j^{(n)} > 1)$, $j = 1, \dots, M$, т.е. наблюдения
 конечного числа значений $\hat{f}_j^{(n)}$, $n = 1, 2, \dots, j = 1, \dots, m$, позволяют п.н.
 безошибочно определить упорядоченность p_1, \dots, p_m , $m = 1, 2, \dots, M$, а,
 следовательно, — и нечеткую модель Э.

Работа выполнена при финансовой поддержке РФФИ, грант №05-01-00532.

Литература

1. Пытьев Ю.П. Возможность. Элементы теории и применения. Изд-во Эдиториал УРСС, Москва 2000.
1. Pyt'ev Yu. P. Stochastic models of possibility // Pattern Recognition and Image Analysis, 12(4), pp. 376-396, 2002.

О синтезе нелинейных разделителей с использованием спрямляющих пространств

Л.Ю. Романов

(Москва)

В докладе рассматривается метод построения нелинейных разделяющих поверхностей на основе использования спрямляющих

пространств. Предлагается эффективный алгоритм, позволяющий получать спрямляющие пространства низкой размерности.

Актуальность данной задачи обусловлена важностью проблемы отыскания, вообще говоря, нелинейных разделяющих поверхностей для двух произвольных конечных непересекающихся множеств точек в n -мерном евклидовом пространстве. Для построения разделителей применяется алгоритм «Метод опорных векторов» («Support Vector Machine», SVM), разработанный В.Н. Вапником. В случае, когда классы линейно разделимы, SVM находит гиперплоскость, максимизируя ширину разделяющей полосы.

В случае отсутствия линейной разделимости возможно несколько различных подходов. Один из них — разделение объектов обучения нелинейной поверхностью. Для этого строится так называемое *спрямляющее пространство*, т. е. исходное признаковое пространство, расширенное дополнительными осями. При этом новое пространство строится таким образом, чтобы в нем достигалось линейное разделение объектов обучения.

После построения спрямляющего пространства объекты разделяются гиперплоскостью, построенной алгоритмом SVM, а затем эта гиперплоскость проектируется на исходное признаковое пространство. Разделимость объектов при этом сохраняется.

Отождествим объект и соответствующую ему точку в евклидовом пространстве. Будем говорить, что точка принадлежит классу, если соответствующий ей объект принадлежит этому классу. Множество таких точек в евклидовом пространстве обозначим через S . Заметим, что при расширении исходного пространства путем добавлением новых осей множество S изменится, поскольку изменятся его элементы, получив новые координаты.

Рассмотрим множество Q всевозможных отрезков, соединяющих точки разных классов.

Определение 1. Будем называть *дефектом разделяющей гиперплоскости* число непересеченных ею отрезков из множества Q .

Определение 2. Определим *дефект обучающей выборки* как минимум дефекта по всевозможным разделяющим гиперплоскостям: $D(S) = \min_L D(L)$, где L — разделяющая гиперплоскость.

Определение 3. Под *добавлением новой оси к базису* будем понимать преобразование пространства $\mathbf{R}^m \rightarrow \mathbf{R}^{m+1}$, при котором первые m координат точек (x_1, \dots, x_m) сохраняются, а $(m+1)$ -я координата определяется функцией $x_{m+1} = f(x_1, \dots, x_m)$.

Вид функции f зависит от S — множества точек, соответствующих

обучающей выборке в m -мерном пространстве. Обозначим множество таких точек в исходном n -мерном пространстве через S^0 , а в расширенном $(n+k)$ -мерном пространстве — S^k .

Будем обозначать множество объектов обучения из 1-го класса 1S , а множество объектов обучения из 2-го класса — 2S .

Справедливы следующие утверждения.

Теорема 1. *Гиперплоскость разделяет объекты обучающей выборки без ошибок тогда и только тогда, когда она пересекает все отрезки из множества Q .*

Теорема 2. *Добавление новой оси в текущий базис не увеличивает дефект обучающей выборки.*

Рассмотрим исходное n -мерное пространство \mathbf{R}^n и множество точек S^0 , соответствующее обучающей выборке. Построим с помощью алгоритма SVM гиперплоскость $L_{S^0}^0(\vec{x}) = 0$, дающую линейное разделение точек с возможными ошибками классификации. Обозначим значение левой части уравнения гиперплоскости, построенной по выборке S^0 , на объекте s_j^0 как $L_{S^0}^0(s_j^0)$. Тогда, если точка классифицирована верно, то $L_{S^0}^0(s_j^0) > 0$ для точки 1-го класса и $L_{S^0}^0(s_j^0) < 0$ для точки 2-го класса. Если же на некоторых точках эти неравенства не выполняются, то такие точки будем называть *дефектными*.

Используя эти понятия, можно показать справедливость следующего утверждения.

Теорема 3. *Разделяющая поверхность в n -мерном пространстве, задающаяся следующим образом:*

$$L_{S^0}^i(\vec{x}) = L_{S^0}^{i-1}(\vec{x}) + 2 \operatorname{ctg} \alpha_i \cdot f^i(L_{S^0}^{i-1}(\vec{x})), \quad i = 1, \dots, k;$$

$$L_{S^0}^k(\vec{x}) = 0,$$

где углы α_i зависят от f^i — функций, построенных специальным образом, разделяет обучающую выборку так, что количество дефектных точек равно нулю.

Однако построенная указанным способом разделяющая поверхность оказывается в значительной степени разрывной.

Предлагается другой подход, хорошо проявивший себя при решении модельных задач.

Пусть $L_{S^0}^0(\vec{x}) = 0$ — гиперплоскость в пространстве \mathbf{R}^n , построенная с помощью алгоритма SVM. Добавим $(n+1)$ -ю ось в базис и определим

координаты точек по новой оси. Для этого рассмотрим множества дефектных точек из k -го класса

$$V^k = \{V^{k,i} : i = 1, \dots, N_k\} = \{s_j^0 : L_{S^0}^0(s_j^0) < 0, j = 1, \dots, |S^0|\}, k = 1, 2.$$

Определение 4. Назовем *точечным корректором* для точки $P \in \mathbf{R}^n$ функцию $f_P^{r_0, h}(r)$, где $r = \sqrt{\sum_{i=1}^n (x_i - P_i)^2}$, h и r_0 зависят от P , обладающую следующими свойствами:

1. $f_P^{r_0, h}(0) = h > 0$;
2. $f_P^{r_0, h}(r)$ монотонно убывает с ростом r ;
3. $f_P^{r_0, h}(r) = 0$ при $r \geq r_0$.

Величину r_0 определим как расстояние от точки $P \in {}^k S^0$ до ближайшей точки противоположного класса:

$$r_0 = \min_{s_j^0 : s_j^0 \notin {}^k S^0} \sqrt{\sum_{i=1}^n [(s_j^0)_i - P_i]^2}.$$

Построим сумму точечных корректоров для каждой дефектной точки из k -го класса:

$$F_k(x_1, \dots, x_n) = \sum_{i=1}^{N_k} f_{V^{k,i}}^{r_0, h} \left(\sqrt{\sum_{j=1}^n (x_j - V_j^{k,i})^2} \right), k = 1, 2.$$

Тогда итоговое преобразование координат будет задаваться функцией

$$x_{n+1} = F_1(x_1, \dots, x_n) - F_2(x_1, \dots, x_n).$$

Разделяющая поверхность в \mathbf{R}^n определяется уравнением

$$a_0 + \sum_{i=1}^n a_i x_i + a_{n+1} \sum_{i=1}^{N_1} f_{V^{1,i}}^{r_0, h} \left(\sqrt{\sum_{k=1}^n (x_k - V_k^{1,i})^2} \right) - a_{n+1} \sum_{i=1}^{N_2} f_{V^{2,i}}^{r_0, h} \left(\sqrt{\sum_{k=1}^n (x_k - V_k^{2,i})^2} \right) = 0.$$

Литература

1. Burges C. J. C. A tutorial on support vector machines for pattern recognition // Data Mining and Knowledge Discovery. — 1998. — Vol. 2, no. 2. — Pp. 121–167. (<http://citeseer.ist.psu.edu/burges98tutorial.html>)

О максимальных гранях булевых функций с малым числом нулей

М.Ю. Романов

(Москва)

В работе рассматриваются булевы функции с малым числом нулей, задаваемые перечислением нулевых точек $\tilde{m}^i = (\alpha_1^i, \alpha_2^i, \dots, \alpha_n^i)$, $i = 1, 2, \dots, k$:

$$f(x_1, x_2, \dots, x_n) = \bigwedge_{i=1}^k (x_1^{\alpha_1^i} \vee x_2^{\alpha_2^i} \vee \dots \vee x_n^{\alpha_n^i}).$$

Эти функции широко применяются для построения систем логических закономерностей в задачах классификации и распознавания, а также в задачах оптимизации.

Рассматриваемые функции задаются матрицей нулей. В работе [1] вводится некоторый канонический вид этой матрицы и показывается, что каждая функция приводима к этому виду, и достаточно исследовать только функции, матрица нулей M которых обладает следующими свойствами:

в M отсутствуют нулевые и единичные столбцы;

одинаковые столбцы в M расположены последовательно;

из любых двух столбцов, один из которых является отрицанием другого, в M присутствует не более одного.

Следуя [2], будем называть функцию f *полной*, если матрица M_f ее нулевых точек состоит из всех $2^{k-1} - 1$ различных столбцов, исключая нулевой и единичный, причем из каждых двух двойственных столбцов в M_f содержится ровно один.

Задача построения ДНФ рассматриваемой функции простым перемножением скобок является достаточно трудной. В силу широкого использования подобных функций исследование свойств ее ДНФ является очень важной задачей. В этом исследовании заметную роль играют свойства матрицы M .

В работе показана справедливость следующего утверждения.

Утверждение 1. В матрице нулей (число нулей $k \geq 2$) полной функции от n переменных расстояние Хемминга между любой парой строк равно

$$2^{k-2} = \frac{n+1}{2}.$$

Для произвольной функции можно рассмотреть матрицу M попарных расстояний между нулями.

Будем называть *степенью* точки число максимальных граней, в которых она содержится.

В работе рассмотрен новый подход, основанный на представлении

конъюнкции в следующей виде. Выбирается набор столбцов матрицы M и рассматривается, как отдельная матрица. Наборы, являющиеся дополнением к этой матрице, соответствуют граням, покрывающим единичные точки рассматриваемой функции.

С использованием этого подхода получены две теоремы, приведенные ниже.

Утверждение 2. *В классе полных функций степень любой точки, на которой функция равна 1, не меньше, чем 2^{k-3} .*

Теорема (об отсутствии ядровых граней). *Пусть в матрице нулей функции f число строк не меньше 2, отсутствуют нулевые, единичные, а также одинаковые столбцы, и расстояние Хемминга между любой парой строк строго больше 2. Тогда ядро сокращенной ДНФ функции f пусто.*

Литература

1. Журавлев Ю.И., Коган А.Ю. Реализация булевых функций с малым числом нулей дизъюнктивными нормальными формами и смежные задачи // Докл. АН СССР, 1985. Т. 285. № 4. С. 795–799.
2. Журавлев Ю.И., Коган А.Ю. Алгоритм построения дизъюнктивной нормальной формы, эквивалентной произведению левых частей булевых уравнений Нельсоновского типа // Ж. вычисл. матем. и матем. физ. 1986. Т. 26. № 8. С. 1243-1249.

Алгоритм распознавания, основанный на голосовании по наборам закономерностей различных типов

О.В. Сенько, А.В. Кузнецова

(Москва)

Введение

Методы распознавания, основанные на процедурах голосования по системам закономерностей, характерным только для одного классов, включают в себя алгоритмы типа Кора, ЛОРЕГ, СВС [1]. Данные методы демонстрируют достаточно высокую эффективность при решении многих практических задач. Под закономерностями для класса K_j понимаются области признакового пространства, в котором доля объектов K_j существенно отличается от их доли в обучающей выборке или, по крайней мере, в соседних областях. В перечисленных выше методах в значительной степени варьируются способы задания закономерностей, ограничения на содержание в них объектов разных классов, а также методика поиска. Вместе с тем во всех случаях закономерности представляют собой цилиндрические подобласти признакового пространства, описываемые с помощью наборов неравенств над отдельными признаками. Однако такой способ задания закономерностей

безусловно далёк от оптимального в задачах, где учёт взаимодействия признаков существенен для разделения объектов разных классов. Данное обстоятельство явилось мотивацией разработки метода двумерных линейных разделителей [2], в котором закономерности формируются по путём оптимального разбиения совместных областей допустимых значений пар признаков с помощью отрезков прямых с произвольной ориентацией относительно координатных осей. Проведённые на реальных данных эксперименты показали, что использование метода двумерных линейных разделителей позволяет достичь высокой точности распознавания для отдельных задач. Вместе с тем во многих случаях его эффективность оказалась заметно хуже эффективности других методов, включая СВС. Снижение точности распознавания ДЛР по отношению к СВС вероятно связано с тем, что во многих задачах совместное влияние признаков на принадлежность объектов классам адекватно описывается с помощью границ, параллельных координатным осям. При этом увеличение неустойчивости поиска закономерностей при использовании более сложных моделей с линейным разделением, связанное с эффектом перенастройки, приводит к отклонениям от действительно оптимальных границ и к снижению в результате точности распознавания. Вместе с тем во многих задачах учёт взаимодействия для одних пар признаков может приводить к увеличению точности и вести только лишь к снижению устойчивости для других.

Алгоритм с пропорциональной коррекцией

В связи с вышесказанным оптимальным подходом представляется одновременное использование закономерностей, найденных с помощью моделей разбиений различных типов и с различными уровнями сложности. Однако при включение в окончательный набор закономерностей, найденных с помощью более сложных моделей, следует для снижения эффекта перенастройки использовать более “жесткий” критерий отбора, чем при включении в набор простых закономерностей.

Данный подход был реализован в рамках алгоритма распознавания с пропорциональной коррекцией отбора, связанной со сложностью используемой модели разбиений. Как и в описанных ранее методах СВС и ДЛР [1,2] в рассматриваемом подходе качестве оценок за классы K_1, \dots, K_L для некоторого распознаваемого объекта S выступают рассчитанные с помощью процедуры статистически взвешенного голосования [1] оценки значений индикаторных функций указанных классов: $y_1(S), \dots, y_L(S)$. В качестве закономерностей используются подобласти признакового пространства, получаемые путём оптимальных разбиений двумерных областей допустимых значений отдельных признаков или пар признаков в рамках четырёх моделей разбиений

различного уровня сложности. Первые две из них являются одномерными моделями, совершенно аналогичными используемым в методе СВС. Модель III также используется в методе СВС и включает все разбиения области допустимых значений пары переменных с помощью отрезков прямых, параллельных координатным осям. Вторая двумерная модель (модель IV) совпадает с моделью, используемой в методе ДЛР. Модель IV включает все разбиения области допустимых значений пары переменных на две подобласти с помощью отрезков прямых с произвольной ориентацией относительно координатных осей.

На первом этапе метод поиска оптимальных разбиений используется для поиска предварительной системы закономерностей. Оптимальные разбиения строятся в рамках четырёх описанных моделей для одиночных признаков и пар признаков путём оптимизации функционала $F_{xi}^d(R, \tilde{S}_0, K_l)$, описывающего качество оптимальной дихотомии, задаваемой разбиением R . Предположим, что разбиение R индуцирует разбиение обучающей выборки \tilde{S}_0 на подвыборки $\tilde{S}_1, \dots, \tilde{S}_q$.

Функционал $F_{xi}^d(R, \tilde{S}_0, K_l)$ определяется как максимальное значение по множеству

дихотомий $\{(\tilde{S}_1, \tilde{S}_1^c), \dots, (\tilde{S}_q, \tilde{S}_q^c)\}$:

$$F_{xi}^d(R, \tilde{S}_0, K_l) = \eta_{com} \max_{i \in I} [(v_i^l - v_i^c)^2 m_i + (v_{ci}^l - v_{ci}^c)^2 m_{ci}],$$

где $\tilde{S}_i^c = \tilde{S}_0 \setminus \tilde{S}_i$, v_i^l - доля объектов класса K_l в подвыборке \tilde{S}_i , v_{ci}^l - доля объектов класса K_l в подвыборке \tilde{S}_i^c , m_i - число объектов в выборке \tilde{S}_i , m_{ci} - число объектов в выборке \tilde{S}_i^c , коэффициент η_{com} варьируется в зависимости от сложности используемой модели, $i \in I_q$.

Формирование окончательной системы закономерностей производится путём селекции из закономерностей, построенных на первом этапе с учётом сложности используемой модели разбиений. В окончательную систему включаются все базовые множества, являющиеся элементами разбиений, для которых значение функционала качества превышает заранее задаваемое пользователем пороговую величину. Использование дихотомических разбиений позволяет обеспечить один и тот же смысл функционала для моделей различного уровня сложности. Для оценки

эффективности предложенного алгоритма и подбора оптимального значения коэффициента η_{com} был проведен ряд исследований на ряде искусственно сгенерированных и реальных тестовых задач. Исследования не выявили ярко выраженного влияния величины η_{com} на точность распознавания в указанных рамках. В среднем из протестированных значений (0.25, 0.5 и 0.75) более высокими оказались результаты для $\eta_{com}=0.25$. Вместе с тем исследования продемонстрировали также в среднем несколько более высокую точность разработанного метода по сравнению с СВС, ДЛР, а также методами q-ближайших соседей и опорных векторов.

Работа была выполнена при поддержке РФФИ (гранты 05-07-9033, 05-01—00332)

Литература

1. Журавлёв Ю.И. Рязанов В.В. Сенько О.В. РАСПОЗНАВАНИЕ. Математические методы. Программная система. Применения. -Москва: Фазис (в печати).
2. Dokukin A.A. Senko O.V. About new pattern recognition method for the universal program system Recognition. Proceedings of the International Conference I.Tech-2004, , Varna (Bulgaria), 14-24 June 2004,pp. 54-58.

О теоретико-вероятностных и теоретико-возможностных алгоритмах редукции многомерных данных: сравнительный анализ

К.С. Соболев, О.В. Мондрус, В.В. Шишаков
(Москва)

Типичная для экспериментов схема измерения:

$$\xi = Af + \nu, \quad (1)$$

где $\xi \in \mathfrak{R}_n$ - искаженный шумом ν выходной сигнал прибора $A: \mathfrak{R}_m \rightarrow \mathfrak{R}_n$, на вход которого поступил сигнал $f \in \mathfrak{R}_m$.

В докладе рассмотрены модели схемы измерения (1): стохастические модели $[A, \Sigma], [A, F, \Sigma]$, теоретико-возможностная модель $[A, \pi^f, \pi^\nu]$, интервальная модель $[A, I_f, I_\nu]$. Для этих моделей рассмотрены задачи редукции измерения [1, 3, 7].

В задаче редукции для стохастических моделей $[A, \Sigma]$ и $[A, F, \Sigma]$, где F и Σ - ковариационные операторы f и ν , предполагается заданным линейный оператор $U: \mathfrak{R}_m \rightarrow \mathfrak{R}(U)$, моделирующий

идеальный измерительный прибор, выходной сигнал Uf которого необходимо синтезировать, и требуется определить такой линейный оператор R , что среднеквадратичная погрешность редукции:

$$h(R, U) = \sup_{f \in R_m} E \|R\xi - Uf\|^2 \sim \min_R$$

Задача редукции для нечеткой модели измерения ставится как задача оптимального оценивания значения параметра $y \in Y$ исследуемого объекта, минимизирующего, например, возможность ошибки оценивания

$$P(d(\cdot)) = \sup_{x \in X, y \in Y} \min (\mu^{\xi, \eta}(x, y), l(y, d(x))) \sim \min_{d(\cdot)} \quad \text{Здесь}$$

функция $d(\cdot) : X \rightarrow Y$ определяет правило оценивания, согласно которому результату измерения $\xi = x$ ставится в соответствие значение $\eta = y = d(x)$ параметра исследуемого объекта. Оптимальное правило d_* определяется из условия $P(d_*(\cdot)) = \min_{d(\cdot)} P(d(\cdot))$ минимизирующего возможность ошибки.

В задаче интервальной редукции считаются известными интервалы

$$I_f = \{f : \underline{f}_i \leq f_i \leq \bar{f}_i, i = 1 \dots m\} \quad \text{и} \quad I_v = \{v : \underline{v}_i \leq v_i \leq \bar{v}_i, i = 1 \dots m\}$$

возможных значений координат сигнала f и шума v . Интервальная оценка $I_U : u_i \in [c_i - l_i, c_i + l_i]$ сигнала Uf определяется как решение задачи линейного программирования:

$$\max_i l_i \sim \sup_{\substack{[c] \\ [l] \in D}} D = \left\{ \begin{array}{l} [c] : \xi - \bar{v} \leq Ac - |A|l \leq Ac + |A|l \leq \xi - \underline{v} \\ [l] : f \leq c - l \leq c + l \leq \bar{f} \end{array} \right\} \quad (2)$$

Целью доклада является продемонстрировать результаты сравнения качественных и скоростных характеристик алгоритмов сверхразрешения многомерных данных. Проведен численный эксперимент для анализа алгоритмов редукции для перечисленных моделей измерительно-вычислительных систем (ИВС) в задачах повышения разрешения. В докладе рассмотрены методы проверки адекватности моделей измерений. В задачах, в которых оператор A определен с точностью до параметров, на основе этих методов решены задачи выбора оператора A по данным измерений.

Если задан класс моделей $[A_\lambda, \Sigma]$ зависящий от параметра λ . тогда, при данном результате измерения ξ , наиболее надежную модель измерительного прибора A_λ можно выбрать исходя из критерия максимальной надежности: $\lambda^*(\xi) = \arg \min_{\lambda} \|(I - A_\lambda A_\lambda^-) \xi\|$ [1,7].

В докладе также рассмотрен эффективный метод проверки адекватности модели регистрации изображений. Пусть модель измерения $[A_\lambda, \Sigma]$ точно соответствует проводимому измерению. Тогда на изображении $x = (I - A_\lambda A_\lambda^-) \xi$, которое является проекцией ξ на $\mathfrak{R}^\perp(A_\lambda)$, будет виден только шум без каких-либо признаков (очертаний) исходного изображения, которые будут заметны в противном случае

В докладе проведены результаты сравнительного анализа эффективных рангов вероятностных и возможностных моделей измерения. Эффективным рангом линейной стохастической модели измерений $[A, \Sigma]$ называется функция:

$$\rho_{[A, \Sigma]}(\varepsilon) = \begin{cases} \max \left(k : \sum_{i=1..k} \varepsilon_i^{-2} \leq \varepsilon \right), & \varepsilon_1^{-2} \leq \varepsilon \\ 0, & \varepsilon_1^{-2} > \varepsilon, \varepsilon > 0, \end{cases}$$

принимая значения $0, 1, \dots, m = \text{rank} A$, где ε_i - решения задачи на собственные значения [1]:

$$A^* \Sigma^{-1} A e_i = \varepsilon_i^2 e_i, \quad i = 1 \dots m, \quad \varepsilon_1^2 \geq \varepsilon_2^2 \geq \dots \geq \varepsilon_m^2.$$

Эффективный ранг характеризует максимальную размерность ортогональной составляющей f которую можно оценить со ср. кв. погрешностью, не превосходящей ε .

Условным эффективным рангом интервальной модели $[A, I_f, I_v]$, при условии, что $\xi = Af + v$ - результат измерения (1), называется функция $\rho_{A, I_f, I_v}(\varepsilon | \xi)$, значение которой при каждом ε равно количеству выполненных неравенств $l_j(\xi) \leq \varepsilon$, [1].

Постановка задачи (2) LP-редукции предусматривает проверку адекватности модели в процессе ее решения: если ограничения на искомый вектор несоместны, то задача не имеет решения, а значит, и модель измерения неадекватна.

Проблемы интерпретации многомерных данных характерны для многих исследовательских и технических задачах. В случае стохастических моделей измерительно-вычислительной системы компромиссным (с точки зрения качества и скорости) методом для повышения качества изображения может быть метод локальной редукции [2], основанный на последовательном оценивании яркости изображения в каждой точке поля зрения по яркости размытого изображения, рассматриваемого в некоторой ограниченной окрестности точки.

Авторы выражают глубокую благодарность своему научному наставнику и руководителю профессору Пытьеву Юрию Петровичу за предложенную тему и обсуждения содержания доклада.

Литература

1. Пытьев Ю.П. Методы математического моделирования измерительно-вычислительных систем - М.: Физматлит - 2002.
2. Соболев К.С., Пытьев Ю.П., Чуличков А.И., Антонюк В.А. Многоапертурный телескоп. Сравнительный анализ алгоритмов сверхразрешения//Pattern Recognition and Image Analysis.
3. Пытьев Ю.П. Возможность. Элементы теории и применения. М.: Эдиториал УРСС, 2000
4. Васильев Ф.П. Численные методы решения экстремальных задач. М.: Наука, 1980. - 512 с.
5. Sayed A.H., Nascimento V.H., Chandrasekaran S. Estimation and control with bounded data uncertainties, Linear Algebra And Its Application, 1998, vol. 284, pp. 259-306.
6. Kailath Th., Sayed A.H., Hassibi B. Linear estimation, 2000, Prentice hall.
7. Пытьев Ю.П., Мондрус О.В., Шишаков В.В. О задаче интервальной редукции измерения//Pattern Recognition and Image Analysis.

Поиск модели оптимальной сложности в задачах нелинейной регрессии

В.В. Стрижов

(Москва)

Широкое практическое применение методов нелинейной оптимизации в регрессионном анализе подготовило базу для создания алгоритмов синтеза регрессионных моделей. Рассматривается процедура поиска оптимальной регрессионной модели в классе моделей, определенном суперпозициями гладких функций из заданного множества. Для поиска используются алгоритмы генетической оптимизации. Параметры моделей оцениваются с помощью методов нелинейной оптимизации.

Поставим задачу нахождения регрессионной модели нескольких свободных переменных следующим образом. Пусть задана выборка –

множество $\{\mathbf{x}_1, \dots, \mathbf{x}_N \mid \mathbf{x} \in \mathbf{R}^M\}$ значений свободных переменных и множество $\{y_1, \dots, y_N \mid y \in \mathbf{R}\}$ соответствующих им значений зависимой переменной. Обозначим оба множества как множество исходных данных D . Эту выборку мы будем рассматривать как результат измерений при проведении некоторого эксперимента, модель которого неизвестна.

Также задано множество $G = \{g \mid g : \mathbf{R} \times \dots \times \mathbf{R} \rightarrow \mathbf{R}\}$ параметрических гладких функций $g = g(\mathbf{b}, \cdot, \dots, \cdot)$. Первый аргумент функции g – вектор-строка параметров \mathbf{b} , последующие – переменные из множества действительных чисел, интерпретируемые как элементы вектора свободных переменных. Рассмотрим произвольную суперпозицию f функций из G , которая задает параметрическую регрессионную модель $f = f(\mathbf{w}, \mathbf{x})$, где вектор $\mathbf{w} \in \mathbf{R}^W$ состоит из присоединенных векторов-параметров функций g . Обозначим $\Phi = \{f_i\}$ – счетное множество всех суперпозиций функций из G .

Требуется найти такую модель f_i , которая доставляет максимум функционала $p(\mathbf{w} \mid D, \alpha, \beta, f_i)$.

Общий подход к выбору нелинейных моделей описан МакКаем в [1] и заключается в следующем. Рассмотрим регрессию $y = f(\mathbf{w}, \mathbf{x}) + v$ с аддитивным Гауссовским шумом с дисперсией σ_v и с нулевым математическим ожиданием. Тогда вероятность появления данных

$$p(y \mid \mathbf{x}, \mathbf{w}, \beta, f) = p(D \mid \mathbf{w}, \beta, f) = \frac{\exp(-\beta E_D(D \mid \mathbf{w}, f))}{Z_D(\beta)},$$

где $\beta = \sigma_v^{-2}$, $Z_D(\beta)$ – нормирующий множитель. Взвешенный функционал ошибки в пространстве данных

$$\beta E_D = \frac{\beta}{2} \sum_{n=1}^N (f(\mathbf{x}_n) - y_n)^2.$$

Точность аппроксимации данных зависит, вообще говоря, от сложности модели и задача оценки наиболее правдоподобных весов в сложных моделях не является корректной в смысле Адамара. Введем регуляризующий параметр α , который отвечает за то, насколько хорошо модель должна соответствовать зашумленным данным.

Функция вероятности весов с заданным параметром α имеет вид

$$p(\mathbf{w} \mid \alpha, f) = \frac{\exp(-\alpha E_W(\mathbf{w} \mid f))}{Z_W(\alpha)},$$

где $\alpha = \sigma_w^{-2}$ соответствует дисперсии распределения весов. Ошибка

$\alpha E_W = \frac{\alpha}{2} \|\mathbf{w}\|^2$ регуляризует веса, начисляя штраф за их чрезмерно большие значения.

Записывая функцию ошибки в виде $S(\mathbf{w} | f) = \alpha E_W + \beta E_D$ получаем

$$p(\mathbf{w} | D, \alpha, \beta, f) = \frac{\exp(-S(\mathbf{w} | f))}{Z_S(\alpha, \beta)}.$$

Для нахождения этого функционала используется приближение рядом Тейлора второго порядка: $S(\mathbf{w}) \approx S(\mathbf{w}^{MP}) + \frac{1}{2} (\mathbf{w} - \mathbf{w})^T A (\mathbf{w} - \mathbf{w})$. Матрица

Гессе функции ошибок определена как $A = \nabla^2 S(\mathbf{w}^{MP}) = \beta \nabla^2 E_D(\mathbf{w}^{MP}) + \alpha I$.

Проблема выбора свободных переменных на каждом элементе суперпозиции является общей проблемой для задач распознавания образов. Для линейных моделей существует хорошо разработанная процедура анализа главных компонент, в которой наиболее важные переменные имеют большую корреляцию с первой главной компонентой. Ле Кюн [2] предложил подобный метод для нелинейных моделей. Он заключается в анализе матрицы Гессе и использует алгоритм сокращения весов. В нем отдельные гиперпараметры связаны с группами весов. В течение обучения гиперпараметры изменяются. По их значению возможно сделать вывод о важности данной свободной переменной.

Гиперпараметры α, β находятся из выражений $2\alpha E_W^{MP} = W - \gamma$ и $2\beta E_D^{MP} = N - \gamma$, где $\gamma = \sum_{i=1}^W \frac{\alpha}{\lambda_i + \alpha}$ и λ_i – собственные значения матрицы A .

Поиск оптимальной модели происходит на множестве моделей, порождаемых на каждой итерации генетического оптимизационного алгоритма. Перед работой алгоритма заданы множество данных D и множество G гладких на области определения свободной переменной функций. Задан начальный набор конкурирующих моделей, $F_0 = \{f_1, \dots, f_L | f \in \Phi\}$, в котором каждая модель f_i есть суперпозиция функций $\{g_{ij}\}_{j=1}^r$. Модели f_i поставлен в соответствие гиперпараметр β_i , функции g_{ij} поставлен в соответствие гиперпараметр α_{ij} , имеющие значения начального приближения. Далее выполняется последовательность шагов, которые повторяются заданное количество раз.

Для каждой модели из набора F минимизируем штрафные функции $S_i(\mathbf{w})$ с помощью процедуры нелинейной оптимизации и получаем веса

\mathbf{w}^{MP} . Определим новые значения гиперпараметров α_{ij} и β_i . Изменение гиперпараметров может быть повторено итерационно после нахождения нового локального минимума $S_i(\mathbf{w})$. После отыскания гиперпараметров моделей выполняются стандартные операции кроссовера, мутации и селекции.

Заданы правила построения производных моделей f'_1, \dots, f'_L . В f_i выбирается функция g_{ij} с наименьшим значением α_{ij} . Выбирается модель f_ξ из $F \setminus \{f_i\}$ и ее функция $g_{\xi\xi}$. Модель f'_i порождается из модели f_i путем замещения функции g_{ij} с ее аргументами на функцию $g_{\xi\xi}$ с ее аргументами.

С заданной вероятностью каждая порожденная модель подвергается мутации. Из множества G случайным образом выбирается функция g' и замещает функцию g_j мутирующей модели. Гиперпараметр α_{ij} этой функции определяется как $\min_j \alpha_{ij}$. Вектор параметров этой функции \mathbf{b}_{ij} назначается при задании G .

Из объединенного множества родительских и порожденных функций в соответствии с критерием S выбираются M наилучших, которые участвуют в дальнейшей оптимизации.

Предлагаемый метод протестирован на задаче по моделированию процесса горения в камере внутреннего сгорания дизельного двигателя.

Данная работа поддержана грантом РФФИ 04-01-00401-а.

Литература

1. MacKay D., Information, inference, learning algorithms. Cambridge University Press, 2003.
1. LeCun, et al., Optimal brain damage. //Touretzky, D.S., Advances in Neural Information Processing Systems 2, p. 598–605., San Mateo, CA, 1990.

Оценка смещения функционала качества в задаче прогнозирования многомерной разнотипной переменной

Т.А. Ступина

(Новосибирск)

Введение

При решении задач анализа данных важной в теоретическом и практическом плане является проблема оценки качества получаемых решений, суть которой заключается в следующем: необходимо найти взаимосвязь между качеством решения, сложностью распределения,

сложностью используемого класса решающих функций и объемом обучающей выборки. В работах данного направления понятие сложности распределения, сложности класса решающих функций формализуется по-разному [1,2,3].

Проблема построения и исследования оценок качества решения является общей для всех задач построения решающих функций по обучающей выборке ограниченного объема (задача распознавания образов, регрессионного анализа, прогнозирование многомерной переменной, анализ временных рядов). Исследования в данном направлении дают возможность строить наилучшую решающую функцию при ограниченном объеме обучающей выборки с учетом сложности распределения, сложности класса решающих функций. Основные результаты решения этой проблемы получены в области построения решающих функций распознавания. Известными работами в данном направлении являются работы Вапника В.Н., Червоненкиса А.Я., Раудиса Ш.Ю. [1,2] Данной проблеме посвящены ряд работ в Институте математики СО РАН [3,4,5].

В работах [6,7] автором предложен метод построения решающей функции прогнозирования многомерной разнотипной переменной в классе логических решающих функций, формализовано понятие сложности класса решающих функций и сложности распределения, предложен способ исследования качества решений, построенных по выборкам ограниченного объема. В данной работе приводятся результаты исследований, проведенные методом статистического моделирования для равномерного распределения.

Постановка задачи

Пусть определено вероятностное пространство $\langle D, \mathcal{B}, P \rangle$, где $D = D_X \times D_Y$, $\dim D_X = n, \dim D_Y = m$, \mathcal{B} – борелевская σ -алгебра на D , $P[D]$ - вероятностная мера на \mathcal{B} (существование такой меры будем обозначать через c); на D определена мера μ такая, что для любого $E \in \mathcal{B}$

$$\mu(E) = \prod_{j=1}^{n \times m} \mu_j(E), \text{ где } \mu_j(E) = \mu(E_j) - \text{мера проекции множества } E \text{ на } j$$

переменную, если переменная непрерывная, то это мера Лебега, если дискретная, то мера Хэмминга. Пусть Φ_0 - класс функций, определенных на D_X со значениями, представленными в виде произвольных множеств $E_y \subset D_Y$, для которых существует функционал:

$$F(c, f) = \int_{D_X} (P(y \in E_y(x) / x) - \mu(E_y(x))) dP(x)$$

Задача прогноза многомерной разнотипной переменной состоит в том, чтобы для произвольного объекта a из генеральной совокупности Γ по известным значениям переменных X_1, X_2, \dots, X_n (описанию объекта) из области D_X предсказать значения целевых (прогнозируемых) переменных Y_1, Y_2, \dots, Y_m из области D_Y на основе анализа имеющейся эмпирической информации (таблицы данных) относительно некоторого критерия качества $F(c, f)$. Оба набора переменных могут быть произвольного типа (дискретные количественные, порядковые, номинальные, бинарные). В качестве предсказания необходимо построить решающую функцию f из заданного класса $\Phi \subseteq \Phi_o$, которая дает наилучший прогноз относительно функционала качества $F(c, f)$. Наилучшей функцией в заданном классе будет функция $f_o = \arg \max_{f \in \Phi} F(c, f)$. В данной работе рассматривается класс логических решающих функций и определяется функционал качества при фиксированном распределении c [7].

Рассматривается зависимость величины смещения эмпирического функционала качества при фиксированной сложности распределения, сложности класса решающих функций от объема выборки:

$$\varepsilon_N(c) = E_{V_N} F(c, \bar{f}) - E_{V_N} F(\bar{f}).$$

Для класса распределений сложности 1 (равномерное в области заданной меры), сложности класса решающих функций M' от 1 до 5 (число областей разбиения), размерности пространств D_Y (m от 1 до 5), D_X ($n=1,2,10,20$) и объемов обучающей выборки N (8, 20, 50) методом математического моделирования были получены значения величины $\varepsilon_N(c)$. Проиллюстрируем некоторые результаты зависимостей на графиках 1 и 2.




рис.1 Зависимость $\varepsilon_N(c)$ от сложности класса решающих функций




рис.2 Зависимость $\mathcal{E}_N(c)$ от размерности m

Работа выполнена при поддержке РФФИ-04-01-00858

Литература

1. Вапник В.Н., Червоненкис А.Я. Теория распознавания образов // Москва: Наука, 1970.
2. Раудис Ш.Ю., Влияние объема выборки на качество классификации.// Статистические проблемы управления. Вильнюс, 1976, Вып.18, с.1-185.
3. Лбов Г.С., Старцева Н.Г. Логические решающие функции и вопросы статистической устойчивости решений // Новосибирск: Изд-во Ин-та математики, 1999, 212с.
4. Berikov V.B. A priori estimates of recognition quality for discrete features // Pattern Recognition and Image Analysis, 2002, Vol. 12, N 3, pp.235-242.
5. Nedel'ko V. M. On the accuracy of Vapnik-Chervonenkis Risk estimations in discrete case. // PRIP'2003, Minsk, Proceeding of the seventh international conference, 2003, Vol 2, pp.75-79.
6. Lbov G.S., Stupina T.A., Statistical Stability of Sampling Decision Functions in Recognition and Prediction Problems // "Pattern Recognition and Image Analysis", Vol. 14, No 2'2004, pp 231-236.
7. T.A. Stupina, The Properties of Risk Function In Heterogeneous Multivariate Prediction. // Proceeding of the 8 international conference, 2005 (PRIP'2005), Minsk, Vol 1, pp 80-83.

Задача линейной оптимизации с прецедентной начальной информацией

Н.Ю. Таратынова

(Севастополь)

Введение

Модель линейного программирования

$$f(x) = (c, x) \rightarrow \max$$

$$Ax \leq b$$

$$x \geq 0$$

- оптимизация линейной функции на множестве решений системы линейных неравенств, проста по своей структуре и, вместе с тем, может быть применена к широкому кругу приложений.

В работе рассматривается ситуация, когда параметры модели: A, b неизвестны, а исходная информация задана в виде набора точек наблюдения с указанием принадлежности этих точек к области допустимых решений. Исследуется возможность применения метода «обобщенного портрета» для синтеза системы ограничений по прецедентной начальной информации.

Синтез системы ограничений

Обозначим: W_1 - множество точек, принадлежащих области допустимых решений, W_2 - множество недопустимых точек.

При построении системы ограничений выделим два этапа:

1. Разбиение множества недопустимых точек на подмножества, каждое из которых линейно отделимо от множества допустимых точек.
2. Построение разделяющих поверхностей для каждого из этих подмножеств по методу «обобщенного портрета».

Алгоритм разбиения множества недопустимых точек:

1. Используя простейшую рекуррентную перцептронную процедуру, строим $s = |W_2|$ гиперплоскостей $L_j(x) = 0$, отделяющих по отдельности каждую точку $x \in W_2$ от всех точек из W_1 .
2. Решаем задачу о минимальном покрытии, отбирающую наименьшее число гиперплоскостей из $\{L_j(x) = 0, j = \overline{1, s}\}$, в совокупности кусочно-линейно отделяющих все точки из W_2 от множества W_1 .
3. Из полученных тупиковых наборов по какому-либо признаку выбирается один набор. Примерами таких признаков могут быть: количество гиперплоскостей в наборе и/или суммарное число

отделяемых каждой гиперплоскостью точек.

Пусть

$$\{L_{r_1}(x) = 0, L_{r_2}(x) = 0, \dots, L_{r_k}(x) = 0\}$$

- выбранный набор гиперплоскостей.

Обозначим $W_2^i \subset W_2, (i = \overline{1, k})$ - множество точек из W_2 , отделяемых гиперплоскостью L_{r_i} от множества W_1 .

Система множеств $\{W_2^i\}_{i=\overline{1, k}}$ - результат работы первого этапа.

На втором этапе для каждого $W_2^i, (i = \overline{1, k})$ требуется построить разделяющую поверхность по методу «обобщенного портрета».

Пусть требуется разделить два конечных множества m -мерных векторов:

$$W_1 \\ W_2^i (i = \overline{1, k})$$

Задача разделения множеств ставится таким образом: необходимо найти уравнение оптимальной гиперплоскости в m -мерном пространстве признаков

$$x \psi_i^0 - b_i^0 = 0$$

которая разделяет точки множеств W_1 и W_2^i и, в то же время, наиболее удалена от выделяемых областей – выпуклых оболочек каждого из этих множеств.

Ищется такое направление ψ_i^0 в полном пространстве признаков, чтобы проекции выпуклых оболочек точек обучающей выборки одного и другого класса на это направление были максимально удалены друг от друга:

$$\psi_i^0 = \max_{\psi} \left[\min_{\tilde{x} \in W_2^i} \tilde{x} \psi - \max_{x \in W_1} x \psi \right]$$

Разделяющая поверхность проводится перпендикулярно выбранному направлению ψ_i^0 через середину отрезка, соединяющего проекции разделяемых областей:

$$b_i^0 = \frac{\min_{\tilde{x} \in W_2^i} \tilde{x} \psi_i^0 + \max_{x \in W_1} x \psi_i^0}{2}$$

Статистический эксперимент

Целесообразность выбора метода «обобщенного портрета» для

построения системы ограничений обосновывается проведенным статистическим экспериментом. Алгоритм метода статистических испытаний включает выполнение N испытаний, в каждом из них задаются случайные значения исходных данных и сравниваются величины ошибки при построении системы ограничений перцептронным алгоритмом и методом «обобщенного портрета». Влияние выбора метода на величину ошибки проверялось по F -критерию Фишера.

Литература

1. Донской В.И., Башта А.И. Дискретные модели принятия решений при неполной информации. Симферополь: Таврия, 1992. С. 149-153
2. Вапник В.Н., Журавель А.А., Червоненкис А.Я. Алгоритмы обучения машин распознаванию образов ОП-1, ОП-2, ОП-3.//Сб. под редакцией В.Н. Вапника «Алгоритмы обучения распознаванию образов». М.: Советское радио, 1973. С. 89-109

Вычисление некоторых геометрических характеристик плоских кривых на основе спектральных методов

Р.К. Тетуев
(Москва)

Введение

Сложные изображения можно достаточно точно описать в виде комплекса геометрических примитивов, например, как набор кривых: используя определенные алгоритмы растровые изображения, переводят в векторные. Векторные представления обладают рядом преимуществ, особенно в задачах, сопряженных с распознаванием визуальных образов.

Итак, представим каждую пространственную кривую в параметрическом виде как функции некоторой переменной (например, времени) и аппроксимируем их конечными ортогональными рядами. Проведение всестороннего анализа полученных кривых можно теперь построить на основе богатого математического наследия из таких известных областей как аналитическая геометрия и теория спектрального представления функций.

Действительно, несложно, например, дать оценку подобия контуров исходя из совпадения их аппроксимативных представлений. Алгоритмические действия при этом оказываются на порядки менее сложными, чем операции с растровыми изображениями. В последнее время в задачах распознавания образов успешно применяется следующий простой и эффективный способ: каждому образу сопоставляется некоторый признак или несколько признаков (часто количественных) таких, что несовпадение признаков двух образов свидетельствует об их несомненном различии, то есть совпадение признаков является

необходимым условием для совпадения образов. Отметим, что точное совпадение признаков, однако не является достаточным основанием для утверждения идентичности этих образов.

Применение такого приема способно резко уменьшить объемы задействованной памяти и требуемых вычислений. Приведем один отвлеченный пример: анализ отпечатков пальцев является простым и надежным способом в деле поиска некоторого человека, если мы располагаем образцом – его дактилоскопическим снимком. Однако если мы дополнительно располагаем набором признаков (например: мужчина 25-35 лет, кареглазый, шатен), мы облегчим и значительно ускорим поиск за счет отсеивания образов, заведомо неподходящих.

Для произвольных кривых, в том числе замкнутых, то есть являющихся контурами некоторых плоских фигур, существует ряд естественных геометрических признаков, таких как длина, кривизна, центр тяжести и площадь фигуры. Данный доклад посвящен рассмотрению способа вычисления этих признаков исходя из принятого нами спектрального аппроксимативного представления.

Вычисление геометрических признаков

Будем считать, что все нами рассматриваемые кривые заданы на плоскости параметрически, в виде пары функций:

$$(x(t), y(t)), \text{ где } t_0 < t < T$$

и данные функции представлены отрезками ортогональных рядов:

$$x((t-a)/m) = \sum_{n=0}^N A_n P_n(t), \quad y((t-a)/m) = \sum_{n=0}^N B_n P_n(t), \quad (1)$$

где $a = (T + t_0)/2$, $m = (T - t_0)/2$, $P_n(t)$ – полиномы Лежандра [1].

Ясно, что если $x(t_0) = x(T)$ и $y(t_0) = y(T)$, то кривая замкнута. Мы можем проверить замкнутость кривых, представленных в виде (1):

$$\sum_{n=0}^N A_n P_n(-1) = \sum_{n=0}^N A_n P_n(1), \quad \sum_{n=0}^N B_n P_n(-1) = \sum_{n=0}^N B_n P_n(1).$$

Очевидно, что одним из признаков замкнутой кривой может служить площадь S фигуры, которую она ограничивает (будем считать, что кривая огибает фигуру против часовой стрелки):

$$S = \int_{t_0}^T xdy = - \int_{t_0}^T ydx.$$

Воспользуемся (1) и сделаем замену переменных $\xi = (t - a) / m$. Тогда:

$$S = \int_{-1}^1 \left(\sum_{n=0}^N A_n P_n(\xi) \right) \left(\sum_{n=0}^N B_n P_n(\xi) \right)' d\xi.$$

Нам известны значения норм $\| P_n \|$ и рекуррентное соотношение:

$$P'_{n+1} = P'_n + (2n + 1)P_n.$$

На основании чего мы можем легко выразить значение площади S через коэффициенты A_n и B_n :

$$S = \sum_{n=0}^{N-1} A_n B_n^*, \text{ где } B_n^* = \sum_{k=0}^{\left[\frac{N-1-n}{2} \right]} B_{n+1+2k}.$$

Таким же образом через коэффициенты разложения представления (1) можно выразить значения других геометрических признаков, таких как длина кривой, кривизна кривой, аффинная длина дуги и так далее.

Заключение

Вычисление геометрических характеристик на практике встречает естественные ограничения, связанные с различного рода помехами. Поэтому применение для этих целей большинства численных методов оказывается трудоемким и зачастую дает неустойчивые результаты. Такое положение вынуждает отказываться от использования многих полезных геометрических признаков, инвариантов в пользу менее эффективных, но проще вычисляемых и более устойчивых. Так, аффинная длина кривой как признак оказалась бы весьма полезной на практике, но она требует оперирования со вторыми производными, в то время как при вычислении площади фигуры, ограниченной кривой, используется лишь первые. Но при сжатии образа значение площади изменится, в отличие от аффинной длины, устойчивой ко всем аффинным преобразованиям кривой [2] и, следовательно, являющейся более выгодным, информативным признаком образа.

Сглаживающая природа и аналитическая «целостность» спектрального представления являются явными преимуществами в решении задач

распознавания плоских фигур и кривых. Благодаря таким свойствам мы способны, на основании достаточно точного представления образа, быстро и легко вычислить значения его признаков. Более того, заметим, что не случайно в качестве базиса были использованы ортогональные полиномы – такой выбор позволил нам получить устойчивые результаты при вычислении производных высоких порядков, в отличие от использования других базисов, к примеру, построенных на тригонометрических функциях. Эффективность разработанной для данных целей теории преобразования отрезков ортогональных полиномиальных рядов позволяет надеяться на успешное применение данного спектрального подхода в различных областях науки и техники.

Литература

1. Дедус Ф.Ф., Куликова Л.И., Панкратов А.Н., Тетуев Р.К. «Классические ортогональные базисы в задачах аналитического описания и обработки информационных сигналов» М.: Московский государственный университет им. М.В. Ломоносова, Факультет Вычислительной математики и кибернетики, 2004.
2. K. Arbter, W. E. Snyder, H. Burkhardt, and G. Hirzinger. Application of Affine-Invariant Fourier Descriptors to Recognition of 3-D Objects. IEEE Trans. Pattern Analy. Machine Intell., 12:640–647, 1990.

Об одном подходе к синтезу «простых» процедур распознавания

М.Г. Тихомиров

(Москва)

Особенностью современных методов синтеза процедур распознавания (алгоритмы вычисления оценок, алгебраический подход и т.д.) оказывается то, что построенные алгоритмы обычно оказываются достаточно сложными. Решения поставленных задач представляют из себя мультиалгоритмические конструкции. Достоинствами данного подхода являются точность, устойчивость полученных решений и т.п.. На практике часто возникают ситуации, требующие построить алгоритм в рамках заданного класса сравнительно простых конструкций, т.е. построение «простого» алгоритма должно проводиться на заданном массиве прецедентов в рамках заданного класса «простых» процедур распознавания.

В докладе обсуждается возможность использования специальной техники нахождения «простых» решений. Суть подхода состоит в том, что на первом этапе строится решение в виде мультиалгоритмической конструкции, удовлетворяющей всем требованиям, кроме простоты. После этого построенный сложный алгоритм используется для генерации дополнительных объектов обучения – виртуальных прецедентов, которые

вместе с исходными прецедентами равномерно заполняют компакт, на котором требуется произвести настройку «простого» алгоритма.

Следующим шагом является настройка «простого» алгоритма уже на расширенном множестве прецедентов. В результате получается решение, удовлетворяющее в определенной степени всем требованиям, в том числе и требованию простоты.

Основной целью поиска «простых» решений задач распознавания или классификации является возможность использования полученных алгоритмов при ручном счете. В частности, эта цель ставится при создании нормативных документов или справочников. Как пример можно также рассмотреть задачу составления рейтингов коммерческих банков. Для определения надежности банка необходимо обработать сотни параметров, что в результате даст точный ответ на поставленный вопрос. В реальных условиях практически невозможно выполнить подобный расчет без использования ЭВМ и специализированных программных комплексов. С помощью предлагаемого подхода синтезируется алгоритм, использующий основные показатели, дающий достаточно точное решение и, в тоже время, позволяющий произвести классификацию банков вручную с помощью «прозрачных» для экспертов вычислений, исключая арифметические ошибки, возникающие при использовании «сложных» мультиалгоритмических конструкций.

Неопределенная стохастическая модель

О.В. Фаломкина, Т.В. Матвеева, Ю.П. Пытьев

(Москва)

Как известно, неопределенная нечеткая (НН) модель позволяет формально учесть мнение исследователя о ее адекватности и выразить его эволюцию, обусловленную получением новых знаний. С другой стороны, для НН моделей характерно, что критерий оптимальности решения, в частности, в задаче оптимального оценивания, зависит от того, какая характеристика качества решения «важнее»: та, что отвечает за «точность», или та, что отвечает за «надежность», адекватность [1,3].

Принцип построения НН модели состоит в следующем: вместо одной теоретико-возможностной модели объекта, которой является пространство с возможностью, исследователь указывает класс таких моделей, задав на этом классе распределение правдоподобий. Так как схема, приведенная в [1], достаточно общая, ее можно распространить на другие области математического моделирования, в частности, на те, где моделью объекта является вероятностное пространство. Получаемые таким образом модели называются *неопределенными стохастическими* (НС).

Как пример применения предложенного в [1] принципа рассмотрим постановку НС задачи идентификации [2]. Пусть ξ — случайный

элемент, принимающий значения в множестве X согласно одному из распределений $pr(\cdot|1), \dots, pr(\cdot|n)$ вероятностей Pr_1, \dots, Pr_n ; $pr(\cdot|k)$ — плотность вероятности Pr_k относительно некоторой фиксированной меры μ , $k = 1, \dots, n$.

Условимся считать, что речь идет о стохастической системе, которая может находиться в одном из n состояний, значение $x \in X$ случайного элемента ξ определяет результат наблюдения за системой, причем если система находится в состоянии с номером k , то значения случайного элемента ξ контролируются распределением $pr(\cdot|k)$, $k = 1, \dots, n$. В задаче идентификации требуется по наблюдению значения $\xi = x$ принять одно из n решений о состоянии системы.

Задачу идентификации рассмотрим для байесовской модели системы, в которой заданы распределения вероятностей q_k^k , $k = 1, \dots, n$, состояний и переходной вероятности $pr^{\xi|k}(\cdot|k): X \rightarrow R_+$ наблюдения ξ для каждого состояния $k = 1, \dots, n$, определяющих совместное распределение ξ и κ равенством $pr^{\xi, \kappa}(x, k) = pr^{\xi|k}(x|k)q_k^k$, $x \in X, k = 1, \dots, n$.

Правило решения о состоянии системы состоит в следующем: если наблюдаемое значение $\xi = x \in X_k$, то принимается решение в пользу распределения $pr^{\xi|k}(\cdot|k)$, $\xi, k = 1, \dots, n$, где X_1, \dots, X_n — некоторое упорядоченное измеримое разбиение множества X значений $\xi: X = \bigcup_{j=1}^n X_j$, $X_i \cap X_j = \emptyset$, $i \neq j, i, j = 1, \dots, n$. Каждое разбиение

$X = \bigcup_{j=1}^n X_j$, обозначаемое далее $\{X_j\}$, определяет *правило идентификации*.

Обозначим $l_{kj} \in [0, 1]$ величину потерь, сопутствующих решению в пользу состояния « j », в то время как на самом деле система находится в состоянии « k », $k, j = 1, \dots, n$. Для правила решения, определенного разбиением $\{X_j\}$, ожидаемый риск

$$L = \sum_{j=1}^n \int_{X_j} S_j(x) \mu(dx) = L(\{X_j\}), \quad (1)$$

где

$$S_j(x) = \sum_{k=1}^n l_{kj} pr^{\xi, \kappa}(x|k) q_k^\kappa, x \in X, j = 1, \dots, n. \quad (2)$$

Решение задачи

$$L(\{X_j\}) \sim \min_{\{X_j\}} \quad (3)$$

дано в теореме (см., например, [2])

Теорема. Минимум в (3) достигается на любом упорядоченном разбиении

$$X = X_1^* \cup \dots \cup X_n^* \quad (X_i^* \cap X_j^* = \emptyset, i \neq j, i, j = 1, \dots, n),$$

удовлетворяющем условию

$$X_j^* \subset \left\{ x \in X, S_j(x) = S(x) = \min_{1 \leq i \leq n} S_i(x) \right\} \stackrel{\text{def}}{=} \bar{X}_j, \quad j = 1, \dots, n. \quad \text{Минимальное}$$

значение риска (1)

$$L^* = L(\{X_j^*\}) = \sum_{j=1}^n \int_{X_j^*} S_j(x) \mu(dx) = \int_X S(x) \mu(dx).$$

Один из способов учесть мнение исследователя в задаче (3) — определить элементы l_{kj} матрицы $\{l_{kj}\}$ потерь в (2) значениями неопределенных элементов \tilde{l}_{kj} , $k, j = 1, \dots, n$. В этом случае ожидаемый риск $L(\{X_j\})$ является неопределенной величиной, и правдоподобие истинности высказывания, согласно которому ожидаемый риск равен e , дается выражением

$$Pl(L(\{X_j\})) = e = \sup \{g^{\tilde{l}_{11}, \tilde{l}_{12}, \dots, \tilde{l}_{nn}}(l_{11}, l_{12}, \dots, l_{nn}), l_{kj} \in [0, 1],$$


$$k, j = 1, \dots, n, \sum_{j=1}^n \int_{X_j} \sum_{k=1}^n l_{kj} pr^{\xi, \kappa}(x, k) \mu(dx) = e\}, e \in [0, 1], \quad (4)$$

где $g^{\tilde{l}_{11}, \tilde{l}_{12}, \dots, \tilde{l}_{nn}}(\cdot, \dots, \cdot) : [0, 1]^{n \times n} \rightarrow [0, 1]$ — совместное распределение правдоподобия неопределенных элементов \tilde{l}_{kj} , $k, j = 1, \dots, n$.

Оптимальным будем считать упорядоченное разбиение $X = \bigcup_{j=1}^n X_j^*$,

минимизирующее правдоподобие *больших* и максимизирующее правдоподобие *малых* значений ожидаемого риска, т.е. решение задачи

$$\sup_{a \geq e} Pl(L(\{X_j\}) = a) \sim \min_{\{X_j\}}, \sup_{a \leq e} Pl(L(\{X_j\}) = a) \sim \max_{\{X_j\}}, e \in [0, 1].$$



В случае $n=2$, $\{\tilde{L}_{ij}\} = \begin{pmatrix} 0 & \tilde{v} \\ \tilde{u} & 0 \end{pmatrix}$, функции

$g^{\tilde{u}, \tilde{v}}(u, v)$, $u, v \in R_+ \times R_+$, представленной на рис., задача (3) сводится к задаче

$$\int_{X_1} \underline{u}pr^{\xi, \kappa}(x, 2)\mu(dx) + \int_{X_2} \underline{v}pr^{\xi, \kappa}(x, 1)\mu(dx) \sim$$

$\sim \min_{\{X_j\}}$, решением которой является любое

упорядоченное разбиение $X = X_1^* \cup X_2^*$, $X_1^* \cap X_2^* = \emptyset$, удовлетворяющее условию (см. рис. и теорему)

$$X_1^* \subset \{x \in X, \underline{u}pr^{\xi, \kappa}(x, 2) \leq \underline{v}pr^{\xi, \kappa}(x, 1)\},$$

$$X_2^* \subset \{x \in X, \underline{u}pr^{\xi, \kappa}(x, 2) \geq$$

$$\geq \underline{v}pr^{\xi, \kappa}(x, 1)\}.$$

Работа выполнена при финансовой поддержке РФФИ, грант №05-01-00532.

Литература

1. Пытьев Ю.П. Неопределенные нечеткие модели и их применения // Интеллектуальные системы, т.8, 2004, вып. 1-4.
2. Yu. P. Pyt'ev. Statistical and Fuzzy Optimal Decisions. I. Statistical Decisions. // Pattern Recognition and Image Analysis (to be published).
3. Фаломкина О.В., Пытьев Ю.П. О критериях оптимальности для неопределенных нечетких моделей. Труды конференции «Математические методы распознавания образов-12».

О критериях оптимальности для неопределенных нечетких моделей

О.В. Фаломкина, Ю.П. Пытьев

(Москва)

Неопределенные нечеткие (НН) модели основаны на сложной, неточной, противоречивой и недостоверной информации. В НН моделях нечеткость, расплывчатость формулировок, относящаяся к содержанию информации, охарактеризована в терминах значений мер возможности и (или) необходимости [1]. Соответственно достоверность формулировок, истинность которых не может быть абсолютной, охарактеризована в

терминах значений мер правдоподобия и (или) доверия [2].

Пусть $(Y, \mathcal{P}(Y), P^n)$ – пространство с возможностью, которое состоит из множества Y элементарных событий, σ -алгебры $\mathcal{P}(Y)$ всех подмножеств Y , называемых событиями, и функции $P^n(\cdot): \mathcal{P}(Y) \rightarrow [0, 1]$, называемой мерой возможности (возможностью). Значение $P^n(A)$ называется возможностью события $A \in \mathcal{P}(Y)$.

Возможность $P^n(\cdot)$ определена ее значениями $f^n(y) \stackrel{\text{def}}{=} P^n(\{y\}) = P^n(\eta = y), y \in Y$, на одноточечных множествах $\{y\} \subset Y$, а именно, $P^n(A) \stackrel{\text{def}}{=} P^n(\eta \in A) = \sup_{y \in A} f^n(y), A \in \mathcal{P}(Y)$. Функция $f^n(\cdot): Y \rightarrow [0, 1]$ называется распределением возможностей значений канонического нечеткого элемента $\eta(\cdot): (Y, \mathcal{P}(Y), P^n) \rightarrow [0, 1]$ и распределением возможности $P^n(\cdot)$ [2]. Пусть аналогично $(U, \mathcal{P}(U), P^{\tilde{u}}(\cdot))$ — пространство с правдоподобием, состоящее из множества U элементарных высказываний, σ -алгебры $\mathcal{P}(U)$ всех подмножеств (высказываний), и функции $P^{\tilde{u}}(\cdot): \mathcal{P}(U) \rightarrow [0, 1]$, называемой мерой правдоподобия. Аналогично возможности $P^n(\cdot)$, правдоподобие $P^{\tilde{u}}(\cdot)$ индуцируется распределением правдоподобий $g^{\tilde{u}}(\cdot): U \rightarrow [0, 1]$ значений канонического неопределенного элемента $\tilde{u}(\cdot): (U, \mathcal{P}(U), P^{\tilde{u}}(\cdot)) \rightarrow U$ [2].

Неопределенный элемент, в отличие от нечеткого элемента, моделирующего все то, что относится к содержательной интерпретации свойств объекта, моделирует неполноту знания этих свойств.

НН элементом, принимающим значения в X , называется образ $\tilde{\xi} \stackrel{\text{def}}{=} q(\eta, \tilde{u})$ (упорядоченной) пары (η, \tilde{u}) — нечеткого η и неопределенного \tilde{u} элементов при отображении $q(\cdot, \cdot): Y \times U \rightarrow X$. Пространства $(Y, \mathcal{P}(Y), P^n)$ и $(U, \mathcal{P}(U), P^{\tilde{u}}(\cdot))$ называются базовыми для $\tilde{\xi}$ [2].

Для каждого фиксированного $\tilde{u} = u \in U$, $\xi_u = \xi|_{\tilde{u}=u} = q(\eta, u)$ — нечеткий элемент. Его распределение параметрически зависит от $u \in U$:

$$P^\eta(\xi_u = x) = f^{\xi_u}(x) = \sup\{f^\eta(y) \mid y \in Y, q(y, u) = x\}, x \in X.$$

Семейство $\xi_u, u \in U$, нечетких элементов есть нечеткая функция $\xi: U \rightarrow X$, соответственно возможность $P^\eta(\xi_u = x) \equiv P^\eta(\tilde{\xi} = x) = f^{\tilde{\xi}}(x)$ равенства $\tilde{\xi} = x$ есть неопределенное число из $[0, 1]$, а распределение возможностей $f^{\tilde{\xi}}(x), x \in X$, — неопределенная функция. В частности, $g^{f^{\tilde{\xi}}(x)}(p) = Pl^u(f^{\tilde{\xi}}(x) = p) = \sup\{g^u(u) \mid u \in U, f^{\xi_u}(x) = p\} \stackrel{def}{=} \tau_x^{\tilde{\xi}}(p), p \in [0, 1]$, — правдоподобие истинности высказывания, согласно которому p — возможность равенства $\tilde{\xi} = x \in X$ [2].

Высказывание «возможность равенства $\tilde{\xi} = x$ равна p » относительно НН элемента $\tilde{\xi}$ называется элементарным. Функция $\tau_x^{\tilde{\xi}}(p) \stackrel{def}{=} Pl(P(\tilde{\xi} = x) = p), x \in X, p \in [0, 1]$ называется распределением правдоподобия возможностей значений НН элемента $\tilde{\xi}$, или короче — распределением $\tilde{\xi}$.

Рассмотрим постановку задачи НН интерпретации наблюдения. Пусть в эксперименте регистрируется сигнал $x \in R_k$, являющийся искаженным ошибкой n выходным сигналом измерительного прибора A

$$x = Af + n, \quad (1)$$


где $A: R_m \rightarrow R_k$ - оператор, моделирующий измерительный прибор, R_m, R_k - евклидовы пространства, m, n - их размерности, $f \in F$ — неизвестный входной сигнал, $F \subset R_m, N \subset R_k$ — множества, априори содержащие f и соответственно n . В нечеткой модели (1) f и n — значения нечетких элементов φ и ν , $\pi^\varphi(\cdot): F \rightarrow [0, 1]$, $\pi^\nu(\cdot): N \rightarrow [0, 1]$ — их распределения [1].

Если истинность нечеткой модели $[A, \pi^\nu(\cdot), \pi^\varphi(\cdot)]$ [1] сомнительна, то

в схеме (1) $n \in N$, $f \in F$ - значения НН векторов $\tilde{v} \in N$, $\tilde{\varphi} \in F$, $[A, \tau_f^\varphi(\cdot), \tau_v^v(\cdot)]$ - ее НН модель.

В задаче НН оценивания требуется определить правило оценивания $y(\cdot): R_k \rightarrow F$, которое

каждому $\tilde{\xi} \in R_k$ ставит в соответствие оценку $\tilde{\varphi}_* = y(\tilde{\xi}) \in F$ НН элемента $\tilde{\varphi} \in F$ [2].



НН модель ошибки \tilde{V} зададим распределением нечеткого элемента $v_u = \tilde{V}|_{u=u}$ для каждого значения

$u \in U = R_+$ неопределенного элемента \tilde{u} равенством

$$f^{v_u}(x) = h(\|x\|, u) = 1 -$$

$$\|x\|/u, 0 \leq \|x\| \leq u; 0, \|x\| > u, u > 0, x \in X = R_1; f^{v_0}(0) = h(0, 0) \stackrel{def}{=} 1,$$

см. рис.(а). Распределение $g^{\tilde{u}}(\cdot)$ представлено на рис.(б). НН модель $\tilde{\varphi}$

определим распределением правдоподобия возможностей $\tau_f^\varphi(p) = 1,$

если $p = 1$; 0, если $0 \leq p < 1$, $f \in F$, согласно которому о $\tilde{\varphi}$ априори ничего не известно.

Одной из характеристик качества оценивания $\tilde{\varphi}$ является возможность ошибки, сопутствующей правилу $y(\cdot)$: чем она меньше, тем правило лучше. Другой характеристикой качества правила $y(\cdot)$ является его правдоподобие Pl и (или) доверие Bel [2].

Если возможность ошибки «важнее» ее правдоподобия, то оптимальным является правило $y(\cdot)$, минимизирующее правдоподобие больших и максимизирующее правдоподобие малых возможностей ошибки оценивания, т.е.-решение задачи [2]

$$Pl(P(y(\cdot)) \geq p) \stackrel{def}{=} \sup_{a \geq p} Pl(P(y(\cdot)) = a) \sim \min_{y(\cdot): R_n \rightarrow F},$$

$$Pl(P(y(\cdot)) \leq p) \stackrel{def}{=} \sup_{a \leq p} Pl(P(y(\cdot)) = a) \sim \max_{y(\cdot): R_n \rightarrow F}, p \in [0, 1]. \quad \text{Если}$$

дове-рие «важнее» возможности, то решение задачи

$$Pl(P(y(\cdot)) \geq p) \sim \min_{y(\cdot): R_n \rightarrow F},$$

$$Bel(P(y(\cdot)) \geq p) \stackrel{def}{=} \inf_{a \geq p} Bel(P(y(\cdot)) = a) \sim \min_{y(\cdot): R_n \rightarrow F}, p \in [0, 1],$$

мини-

мизирует правдоподобие и доверие больших возможностей ошибки. Если возможность и доверие «равноценны», то решение задачи

$$Pl(P(y(\cdot)) \geq p) \sim \min_{y(\cdot): R_n \rightarrow F},$$

$$Bel(P(y(\cdot)) \leq p) \stackrel{def}{=} \inf_{a \leq p} Bel(P(y(\cdot)) = a) \sim \min_{y(\cdot): R_n \rightarrow F}, p \in [0, 1],$$

минимизирует правдоподобие больших и доверие малых возможностей ошибки.

Работа выполнена при финансовой поддержке РФФИ, грант №05-01-00532.

Литература

1. Пытьев Ю.П. Возможность. Элементы теории и применения. Изд-во Эдиториал УРСС, Москва 2000.
2. Пытьев Ю.П. Неопределенные нечеткие модели и их применения // Интеллектуальные системы, т.8, 2004, вып.1-4, с. 147-310.

О вычислительной сложности задачи о минимальном аффинном разделяющем комитете

М.Ю. Хачай
(Екатеринбург)

Введение

Аффинным разделяющим комитетом для конечных множеств $A, B \in R^n$ называется [1] такая конечная последовательность функций (f^1, f^2, \dots, f^q) , элементов базового множества $\mathcal{F} = \{f(x, \beta, \gamma) = (\beta, x) + \gamma \mid \beta \in R^n, \gamma \in R\}$, что

$$f^i(x) \neq 0 \quad (x \in A \cup B, i \in N_q) \quad \text{и} \quad \text{sign} \left(\sum_{i=1}^q \text{sign} f^i(x) \right) = \begin{cases} 1, & x \in A, \\ -1, & x \in B. \end{cases}$$

По определению, аффинный комитет безошибочно классифицирует

элементы обучающего множества, т.е. является корректным алгоритмом распознавания. Соображения минимизации сложности решающих правил, получаемых на этапе обучения, приводят к необходимости построения разделяющих комитетов с наименьшим возможным числом элементов. В сообщении исследуется вычислительная сложность соответствующей комбинаторной задачи – задачи о минимальном аффинном разделяющем комитете.

Условия существования

Известен следующий критерий существования разделяющего комитета.

Теорема ([2]). *Аффинный разделяющий комитет для конечных множеств $A, B \in R^n$ существует тогда и только тогда, когда $A \cap B = \emptyset$. Минимальный аффинный комитет содержит не более $|A \cup B|$ элементов.*

Сопоставим задаче поиска аффинного разделяющего комитета систему неравенств

$$\begin{cases} (\beta, a) + \gamma > 0 & (a \in A) \\ (\beta, b) + \gamma < 0 & (b \in B). \end{cases} \quad (1)$$

Обозначим через r ранг системы (1) и сформулируем несколько достаточных условий существования разделяющего комитета.

Утверждение 1. *Пусть каждая подсистема системы (1) ранга k , $0 < k < r$ имеет комитетное решение, состоящее из не более чем q элементов. Тогда существует аффинный разделяющий комитет для множеств A и B , число элементов которого ограничено сверху числом*

$$2q \left\lceil \frac{\lfloor (m-1)/2 \rfloor}{k} \right\rceil + 1.$$

Утверждение 2. *Пусть каждая подсистема системы (1) из $k+1$ неравенства, где $0 < k < r$, совместна, тогда существует разделяющий аффинный комитет для множеств A и B , состоящий из не более чем $2 \left\lceil \frac{\lfloor (m-k)/2 \rfloor}{k} \right\rceil + 1$ элемента.*

Утверждение 3. *Пусть дополнительно к условию утв. 2 найдется подсистема системы (1) мощности μ , обладающая комитетным решением из $2q-1$ элемента. Тогда существует разделяющий аффинный комитет, разделяющий множества A и B , и состоящий из не более чем $2q \left(1 + \left\lceil \frac{m-\mu}{k} \right\rceil \right) - 1$ элемента.*

Задачи о минимальном комитете

Далее будем полагать, что $A, B \in Q^n$. Рассмотрим несколько комбинаторных задач.

Задача «Минимальный аффинный разделяющий комитет» (MADC): Задано натуральное число $n > 1$ и множества $A, B \in Q^n$ где $A = \{a_1, a_2, \dots, a_{m_1}\}$, $B = \{b_1, b_2, \dots, b_{m_2}\}$. Требуется найти аффинный разделяющий комитет множеств A и B с наименьшим числом элементов (или показать, что множества неразделимы комитетом).

Задача «Аффинный разделяющий комитет из 3-х элементов» (3-ADC): Задано натуральное число $n > 1$ и множества $A, B \in Q^n$ аналогично предыдущей задаче. Существует ли аффинный разделяющий комитет для множеств A и B , состоящий из трех элементов?

Сформулированные задачи тесно связаны с задачами поиска комитетных решений несовместных систем линейных алгебраических неравенств над Q^n . Как обычно, комитетным решением системы линейных неравенств

$$(a_j, x) > 0 \quad (j \in N_m = \{1, 2, \dots, m\}) \quad (2)$$

назовем конечную последовательность векторов (x^1, x^2, \dots, x^q) (в данном случае с рациональными компонентами), удовлетворяющих условию

$$\left| \{i \in N_q : (a_j, x^i) > 0\} \right| > q/2 \quad (j \in N_m).$$

Задача «Минимальный комитет системы линейных неравенств» (MCLE): Заданы натуральные числа m и $n > 1$ и векторы $(a_1, a_2, \dots, a_m) \in Q^n$. Требуется найти комитетное решение (комитет) системы (2) с наименьшим числом элементов (или показать, что система не имеет комитетных решений).

Задача «Комитет из 3-х элементов системы линейных неравенств» (3-COMLE): Заданы натуральные числа m и $n > 1$, и векторы $(a_1, a_2, \dots, a_m) \in Q^n$. Существует ли комитетное решение системы (2), состоящее из трех элементов?

Теорема [3]. Задача MCLE NP-трудна. Задача 3-COMLE NP-полна.

Аналогичные утверждения справедливы и для сформулированных выше задач поиска аффинных разделяющих комитетов. Как обычно, полагаем далее две комбинаторные задачи полиномиально эквивалентными, если

они взаимно сводятся друг к другу по Тьюрингу (за полиномиальное время).

Теорема 1. Задачи *MCLE* и *MADC* полиномиально эквивалентны. Задачи *3-COMLE* и *3-ADC* – также полиномиально эквивалентны.

Теорема 2. Задача *MADC* *NP*-трудна. Задача *3-ADC* *NP*-полна.

Заметим, что задача *MADC* (*3-ADC*) остается *NP*-трудной (*NP*-полной), даже если справедливо условие $A \cup B \subset \{z \in \{-1, 0, 1\}^n \mid (z, z) \leq 3\}$. Заметим также, что известны некоторые дополнительные ограничения, налагаемые на разделяемые множества, при которых исследуемые задачи становятся полиномиально разрешимыми.

Работа выполнена при поддержке РФФИ (гранты № НШ 792.2003.1, 04.01.96104 и 04.01.00108), а также Фонда содействия отечественной науке.

Литература

1. Mazurov V.I., Khachai M.Yu., Rybin A.I. Committee Constructions for Solving Problems of Selection, Diagnostics and Prediction. // Proceedings of the Steklov Institute of mathematics. Suppl. 1, (2002), S67-S101
2. Мазуров В.Д. Метод комитетов в задачах оптимизации и классификации – М.: Наука, 1990
3. Khachay M.Yu. On Computational Complexity of the Minimal Committee Problem // Pattern Recognition and Image Analysis. 2005. vol. 15, no. 1, pp. 59-61.

Прикладные аспекты теории канонических систем счисления в полях алгебраических чисел

В.М. Чернов

(Самара)

«То, каким образом мы выполняем арифметические действия, тесно связано с тем, каким образом мы представляем числа, с которыми работаем; поэтому наше изучение арифметики естественно начать с обсуждения принципиальных способов представления чисел».

Д. Кнут, «Искусство программирования для ЭВМ».

Введение

Суждение, вынесенное в эпиграф, представляется бесспорным: сомневающиеся коллеги могут сами убедиться в этом, попробовав написать программу сложения чисел, заданных в римской системе счисления. В цитированном источнике – фундаментальном многотомнике Д.Кнута приведены достаточно подробные исторические обзоры как возникновения и развития различных систем счисления, так и работ по непосредственному применению различных систем счисления к задачам

информатики.

В работах [1],[2] введено понятие канонической системы счисления в кольце целых элементов квадратичного поля $\mathbf{Q}(\sqrt{d})$ (то есть, в двумерной алгебре).

Определение. Целое алгебраическое число α квадратичного поля $\mathbf{Q}(\sqrt{d})$, равное

$$\alpha = \begin{cases} A \pm \sqrt{d}, & \text{если } d \equiv 2, 3 \pmod{4}; \\ (B \pm \sqrt{d})/2, & \text{если } d \equiv 1 \pmod{4} \end{cases}$$

называется основанием канонической системы счисления в кольце целых элементов квадратичного поля $\mathbf{Q}(\sqrt{d})$, если любой целый элемент этого поля однозначно представим в форме конечной суммы

$$z = \sum_{j=0}^{k(z)} z_j \alpha^j, \quad z_j \in \mathbf{N} = \{0, 1, \dots, |\mathbf{Norm}(\alpha)| - 1\}$$

Пара $\{\alpha, \mathbf{N}\}$ называется *канонической системой счисления* в кольце целых поля $\mathbf{Q}(\sqrt{d})$.

Из результатов работ [1],[2] следует, в частности, что существуют только три квадратичных поля, в кольцах целых элементов которых существуют бинарные системы счисления:

- (а) кольцо целых гауссовых чисел $\mathbf{Z}(i) \subset \mathbf{Q}(i)$ с основаниями, равными $\alpha = -1 \pm i$;
- (б) кольцо $\mathbf{S}(i\sqrt{7}) \subset \mathbf{Q}(i\sqrt{7})$ с основаниями, равными $\alpha = (-1 \pm i\sqrt{7})/2$;
- (с) кольцо $\mathbf{S}(i\sqrt{2}) \subset \mathbf{Q}(i\sqrt{2})$ с основаниями, равными $\alpha = \pm i\sqrt{2}$.

Аналогично, существует только три квадратичных поля, в кольцах целых элементов которых существуют тернарные системы счисления:

- (а) поле $\mathbf{Q}(i\sqrt{2})$ с основаниями $\alpha = -1 \pm i\sqrt{2}$;
- (б) поле $\mathbf{Q}(i\sqrt{3})$ с основаниями $\alpha = (-3 \pm i\sqrt{3})/2$;
- (с) поле $\mathbf{Q}(i\sqrt{11})$ с основаниями $\alpha = (-1 \pm i\sqrt{11})/2$.

В последующих работах (см., например, [3],[4]) понятие канонических систем счисления обобщено на неквадратичные поля алгебраических

чисел.

Работы [1],[2] опубликованы в журналах, малоизвестных не только специалистам в области информатики, но и «чистым» математикам, что, по мнению автора, и объясняет почти пятнадцатилетнее отсутствие прикладных работ, использующих теорию канонических систем счисления.

Автор доклада ставит своей целью частично заполнить этот пробел, указав перспективные приложения и ознакомив с уже полученными результатами.

Рассматриваемые задачи

1. Синтез алгоритмов параллельной машинной арифметики с представлением данных в полях алгебраических чисел.
2. Решение многомерной количественной формы задачи Бореля построения нормальных алгебраических чисел.
3. Синтез многомерных генераторов случайных точек
4. Разработка теории многомерных ортогональных преобразований с хаотическими базисами.
5. Синтез «Хааро-подобных» базисов вейвлет-преобразований.
6. Криптографические приложения.

Отдельные результаты, касающиеся перечисленных задач, публиковались автором в [5]-[12].

Литература

1. Kátai I., Kovács B. Kanonische Zahlensysteme in der Theorie der quadratischen Zahlen // Acta Sci. Math. Szeged, 1980. v. 42. pp. 99-107.
2. Kátai I., Kovács B. Canonical Number Systems in Imaginary Quadratic Fields // Acta Math. Acad. Sci. Hungaricae, 1981. v. 37. pp. 159-164.
3. S.Akiyama, A. Petö. On Canonical number systems // Theoretical Computer Science, 270, 2002, pp. 921-933.
4. A.Kovacs. Generalized binary number systems. // Annales Univ. Sci. Budapest, Sect. Comp.20, 2001, pp.195-206.
5. V. M. Chernov. Canonical Number Systems and Two-Dimensional Uniform Distribution // Pattern Recogn. and Image Analysis V.15, No. 1, 2005, p. 143
6. Чернов В.М., Бесполитов О.В. Параллельные алгоритмы вычисления свертки в редуцированных канонических системах счисления для квадратичных полей // Искусственный интеллект № 2, 2004, с. 197-200.
7. Chernov V.M., Pershina M.V. “Error-free” calculation of the convolution using generalized Mersenne and Fermat transforms over algebraic fields. // Lecture Note Computer Science, No 1296, Springer, 1997, pp.621-628.
8. Chernov V.M. Fast algorithm for “error-free” convolution computation using Mersenne-Lucas codes // Chaos, Solitons and Fractals (в печати).
9. Чернов В.М., Радченко Н.В. Многомерное обобщение количественной

- задачи Бореля //Искусственный интеллект № 2, 2004, с. 201-206.
10. Chernov V.M. Fast uniform distribution of sequences for fractal sets //Proceedings of International Conference on Computer Vision and Graphics 2004, Warsaw, Poland (в печати).
11. A.N.Kalouguine, V.M.Chernov. 3D Generalization for LFSR Random Point Generator // Proceedings of the Second IASTED Int. Multi-Conference “Signal and Image Processing”, 2005, Novosibirsk, Russia. pp.122-125.
12. Chernov V.M. Two-dimensional discrete orthogonal transforms with “chaotic” bases functions // Chaos, Solitons and Fractals (в печати).

Гиперкомплексное дискретное преобразование Фурье произвольной размерности: параллельный подход

М.А. Чичева, М.В. Алиев

(Самара)

Различные способы алгебраического представления сигналов уже прочно вошли в практику обработки изображений и многомерных сигналов. Задачи робототехники (зрения роботов) [6], [10], распознавания образов [9], спектрального анализа, фильтрации [4], [5] и многие другие могут быть решены с использованием многомерной гиперкомплексной алгебры. В частности, в работах [6], [11] исследуется использование многомерного гиперкомплексного дискретного преобразования Фурье (ГДПФ) [1], [2], [3]:

$$F(m_1, \dots, m_d) = \sum_{n_1, \dots, n_d=0}^{N-1} f(n_1, \dots, n_d) W^{<\mathbf{m}, \mathbf{n}>}, \quad (1)$$

$$W^{<\mathbf{m}, \mathbf{n}>} = \prod_{k=1}^d w_k^{m_k n_k}, \quad w_k^N = 1.$$

Характерной особенностью преобразования (1) является то, что комплексные корни N -й степени из единицы w_k лежат в различных подалгебрах некоторой 2^d -мерной гиперкомплексной алгебры \mathbf{B}_d .

Основной проблемой при увеличении размерности обрабатываемых сигналов является быстрый рост вычислительной сложности базовых операций в гиперкомплексной алгебре, и, соответственно, рост вычислительной сложности алгоритмов в целом.

В настоящей работе рассматривается параллельный подход к вычислениям в гиперкомплексной алгебре применительно к быстрым алгоритмам ГДПФ. Следует отметить, что при решении большинства

прикладных задач, в которых существенную роль играет именно гиперкомплексное ДПФ, выбор структуры алгебры \mathbf{B}_d может варьироваться. Существенным требованием для алгебры \mathbf{B}_d является лишь наличие «достаточного» количества подалгебр, изоморфных алгебре комплексных чисел \mathbf{C} .

В рамках работы была рассмотрена 2^d -мерная ассоциативно-коммутативная алгебра \mathbf{B}_d изоморфная прямой сумме комплексных алгебр \mathbf{C} . Синтезирован эффективный алгоритм параллельного выполнения операции умножения гиперкомплексных чисел (для произвольного d). Разработан быстрый алгоритм параллельного вычисления преобразования (1), который, в дополнение к распараллеливанию основных операций в алгебре \mathbf{B}_d , использует естественный параллелизм редукции Кули-Тьюки быстрого алгоритма ДПФ. Избыточность представления вещественных данных, как элементов многомерной алгебры компенсируется применением методов «совмещенного» вычисления частей спектра.

В докладе приводятся теоретические оценки вычислительной сложности, а также результаты экспериментальных исследований. В частности, на рис.1 приводятся зависимости времени t вычисления двумерного ГДПФ от размера $N \times N$ входного сигнала. Здесь p - количество процессоров.




Рис.1. Время вычисления двумерного ГДПФ

Эффективность распараллеливания колеблется от 40 до 90%. Для сравнения отметим, что эффективность распараллеливания классического

ДПФ составляет от 20 до 60% (см., например, [7], [8]).

В докладе анализируются достоинства и недостатки представленного алгоритма, перспективы его развития и применения.

Благодарности

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); а также при поддержке Российского фонда фундаментальных исследований (РФФИ), проекты № 03-01-00736, 05-01-96501.

Литература

1. Алиев М.В. Быстрые алгоритмы d -мерного ДПФ вещественного сигнала в коммутативно-ассоциативных алгебрах $2d$ размерности над полем действительных чисел //Компьютерная оптика, 2002, №24, С. 130-136.
2. Aliev M.V. Synthesis of Two-Dimensional DFT Algorithms in the Hypercomplex Algebra //Pattern Recognition and Image Analysis, International Academic Publishing Company “Nauka/Interperiodica, 2003, Vol. 13, No. 1, pp. 61-63.
3. Aliev M.V., Chernov V.M. Two-dimensional FFT-like algorithms with overlapping //Optical Memory and Neural Networks (Information Optics), 2002, Vol. 11, No. 1, pp. 29-38.
4. Bülow T., Sommer G. Hypercomplex signals - A novel extension of the analytic signal to the multidimensional case //IEEE Transactions on Signal Processing, IEEE Signal Processing Society, 2001, Vol. 49, No. 11, pp.2844-2852
5. Chaitelin F., Meškauskas T. Computation with hypercomplex numbers //Nonlinear analysis, 2001, No. 47, pp. 3391-3400
6. Geometric Computing with Clifford Algebra (G. Sommer (Ed.)) //Springer Series in Information Sciences, Springer-Verlag, Berlin, 2001
7. Gupta A., Kumar V. The scalability of FFT on Parallel Computers //IEEE Transactions on Parallel and distributed systems, IEEE Computer Society, 1993, Vol. 4, No. 8, pp. 922-932
8. Inda M.A., Bisseling R.H. A simple and efficient parallel FFT algorithm using the BSP model //Parallel Computing, 2001, Vol. 27, No. 14, pp.1847-1878.
9. Labunets E.V., Labunets V.G., Egiazarian K., Astola J. Hypercomplex moments application in invariant image recognition //Int. Conf. On Image Processing 98, 1998, pp. 256–261
10. Sommer G. A geometric algebra approach to some problems of robot vision //Computational Noncommunicative Algebra and Applications, Kluwer

Academic Publishers, J. Byrnes ed., NATO Science Series, 2004, No. 136, pp. 309-338

11. Vanwormhoudt M.C. Rings of hypercomplex numbers for NT Fourier transforms //Signal Processing, 1998, Vol. 67, pp. 189–198

**Математические аспекты проблемы идентификации
центров рассеяния на базе обработки спектров EXAFS:
выбор материнского вэйвлета**

М.В. Чукалина, Х. Функе, С.Л. Шабельникова
(Черноголовка)

Аннотация

В работе представлен алгоритм обработки протяженной структуры рентгеновских спектров поглощения (EXAFS), в основу которого положено использование вэйвлет преобразования. Дано краткое введение в теорию формирования спектров, приведено обоснование применения вэйвлет преобразования для их обработки и мотивирован первоначальный выбор вэйвлета Морлет в качестве материнского. Далее приведен пример, который демонстрирует необходимость поиска нового оптимального вэйвлета. Введен критерий оптимальности. Обсуждаются результаты, полученные при использовании модельного спектра в качестве материнского вэйвлета.

Формирование рентгеновских спектров дальней тонкой структуры

Природа и геометрия расположения атомов ближайшего окружения (рассеивающих центров) по отношению к поглощающему атому определяют энергетическое положение особенностей протяженной тонкой структуры рентгеновских спектров поглощения. Под спектром поглощения понимается зависимость коэффициента поглощения рентгеновского излучения в исследуемом образце от длины волны падающего излучения (Рисунок 1,а).

Осциллирующая часть коэффициента поглощения, нормированная на атомное поглощение, определяется соотношением [1]:

$$\chi(k) = \sum_j \frac{1}{kR_j^2} |f_j(k)| \exp\left(-2\sigma_j^2 k^2 - \frac{2R_j}{\gamma(k)}\right) \sin(2kR_j + \varphi_j(k)), \quad (1)$$

где суммирование производится по всем окружающим атомам, R_j - расстояние до j -го атома, $f_j(k)$ - амплитуда обратного рассеяния j -м атомом волны электрона с волновым вектором k (функция, локализованная по k) и под знаком синуса стоит фаза, которая включает разность фаз между падающей и отраженной волной, фазовый сдвиг при движении электрона в потенциале собственного атома и фазовый сдвиг обратного

рассеяния. Если пренебречь фазовым сдвигом и экспоненциальными членами, то акт рассеяния может быть описан синусоидальной функцией, поэтому традиционно Фурье-аппарат используется для анализа $\chi(k)k^3$ (Рисунок 1, б). Частотные компоненты спектра есть суть радиусов координационных сфер. Другой путь, предложенный группой из Екатеринбурга, это решение уравнения методом регуляризации [2].

Обоснование применения вэйвлет преобразования

Как было продемонстрировано [3] амплитуда обратного рассеяния не монотонна и имеет несколько максимумов. По мере роста атомного номера Z положение максимумов функции смещается в область больших k . Если пренебречь фазовым сдвигом и экспоненциальными членами, то выражение (1) может быть переписано в виде:

$$\chi(k) = \sum_j \frac{1}{kR_j^2} |f_j(k)| \sin(2kR_j) \quad (2)$$

Т.о. акт рассеяния описывается синусоидальной функцией с периодом $\frac{\pi}{R_j}$, имеющей максимумы в k -пространстве, в соответствии с положением максимумов амплитуды рассеяния j -го атома. Вэйвлет-преобразование используется для анализа сигналов, имеющих частотно-временную локализацию [4].

Ранее, авторами данной работы было предложено [5] использовать функцию Морле, свойства которой хорошо изучены [4],

$$\psi(t) = \frac{1}{\sqrt{2\pi\sigma}} (e^{i\eta t} - e^{-\eta^2/2}) e^{-t^2/2\sigma^2} \quad (3)$$

в качестве материнского вэйвлета. Выбор этой функции основан на том, что по виду она близка к математической модели формирования сигнала: осциллирующая часть, промодулированная функцией Гаусса. Для ряда образцов [5, 6] авторы получили хорошие результаты по интерпретации спектров с идентификацией центров рассеяния. На рисунке 1. приведен пример, иллюстрирующий интерпретацию измеренного спектра из работы [5]. Показано, что в координационной сфере радиуса 2.8 Å присутствует два типа рассеивателей Zn и O.

Материнский вэйвлет. Разрешение

Выбор материнского вэйвлета определяет разрешение метода, т.е. дает ответ на вопрос как близко в k - и в R - направлениях могут быть расположены “вершины двух гор” на карте вэйвлет преобразования (рисунок 1, в) для того, чтобы они не сливались в одну. Как показано в работе [4] ответ на этот вопрос дает размер частотно-временного окна с

центров в точке $[k, r]$:

$$\left[k - \frac{\eta\sigma}{\sqrt{2r}}, k + \frac{\eta\sigma}{\sqrt{2r}} \right] \times \left[r - \frac{r}{\sqrt{2\eta\sigma}}, r + \frac{r}{\sqrt{2\eta\sigma}} \right] \quad (4).$$

Т.е. если решается вопрос о наличии или отсутствии в координационной сфере радиуса r атомов, для которых положение максимумов амплитуд рассеяния различается на Δ , то ширина частотно временного окна должна быть меньше Δ . Из этого ограничения значения параметров для функции Морле η и σ легко рассчитываются.




Рисунок 1. а) Измеренный спектр. б) Фурье образ спектра.




Рисунок 1 в) Фрагмент вэйвлет-преобразования.

Дело усложняется тем, что в исследуемых образцах подобные ситуации, часто возникают на двух соседних координационных сферах. В этом случае ограничение накладывается не только на ширину частотно-временного окна, но и на его высоту. Нами были обнаружены ситуации, для которых система линейных уравнений для определения η и σ не имела решения.

Применение модельного спектра в качестве материнского вэйвлета

Чтобы повысить разрешение, в работе предлагается использовать модель формирования сигнала в качестве материнского вэйвлета. В качестве параметров модели используются координаты и тип предполагаемого центра рассеяния. Результат вэйвлет преобразования будет получен не в пространстве (радиус координационной сферы, волновой вектор), а в пространстве (параметр масштабирования, волновой вектор). Если на масштабе "1" (точное соответствие модели) для используемого в модели значения волнового вектора наблюдается ярко выраженный максимум, то гипотеза о наличии рассеивающего центра данного типа верна. В докладе обсуждаются полученные результаты.

Работа выполнена при частичной финансовой поддержке РФФИ 05-01-00984 и СРВ.NR.LCG 981353.

Литература

1. Sayers D.E., Lytle F.W., Stern E.A. // *Advanced X-ray Analysis*. N.Y.:Plen. Pr., V. 13, 1970. P. 29.
2. Кочубей Д.И., Бабанов Ю.А., и др. // Рентгеноспектральный метод изучения структуры аморфных тел: EXAFS-спектроскопия. Новосибирск, Наука, 1988. С. 213.
3. Тео В.К. // *EXAFS: Basic Principles and Data Analysis*. Springer, Berlin Heidelberg New York Tokyo, 1986. P. 300.
4. Chui C.K. // *An Introduction to Wavelets*. Academic Press, San Diego, London, 1992. P. 423.
5. Funke H., Scheinost A., Chukalina M. // Wavelet analysis of extended x-ray absorption fine structure data. *Phys. Rev. B* 71, 094110, 2005. (in press).
6. Funke H., Chukalina M., Rossberg A. // Wavelet analysis of Extended X-ray Absorption Fine Structure Data. *Physica Scripta*. Vol. T115, 2005. P. 232-234.

Последовательности расширений конечных множеств некорректных распознающих алгоритмов

З.М. Шибзухов

(Нальчик)

Введение

Рассматривается последовательный подход к построению корректных замыканий конечных множеств некорректных алгоритмов в рамках алгебраического подхода к задачам распознавания [1,2]. Он основан на построении последовательности расширений при помощи алгебраических $\Sigma\Phi$ -операторов ограниченной сложности, которая сходится к корректному замыканию за конечное число шагов.

Стандартная задача распознавания и стандартные преобразования

Пусть задано конечное множество объектов $S = \{S\}$ и его разбиение на Q непустых классов: $S = \bigcup C_q$, где $q \in Q$, $Q = \{0,1,\dots,Q-1\}$. Пусть $y: S \rightarrow Q$ – классифицирующая функция, ставящая в соответствие каждому объекту $S \in S$ номер q класса C_q , такой что $y(S) \in C_q$. Пусть $f: S \rightarrow X$ – преобразование, которое каждому объекту S однозначно ставит в соответствие его описание $x(S) = (x_1(S), \dots, x_n(S))$.

Преобразование f стандартное, если 1) f – сюръективное; 2) $f(S') = f(S'') \Rightarrow y(S') = y(S'')$; 3) $y(S') \neq y(S'') \Rightarrow f(S') \neq f(S'')$; 4) $\forall i = 1, 2, \dots, n$ найдется пара S'_i и S''_i , таких что $x_i(S'_i) \neq x_i(S''_i)$. В этом случае $x(S)$ называется стандартным описанием.

Если f – стандартное, то на множестве X можно однозначно определить функцию $y_1(x)$: для каждого $x \in X$ значение $y_1(x)$ равно номеру класса, в котором содержится множество $f^{-1}(x)$. Тогда $y(S) \equiv y_1(f(S))$ на X , а задача восстановления функции $y(S)$ сводится к задаче восстановления функции $y_1(x)$.

Стандартное преобразование f индуцирует на X разбиение на классы: $S = \bigcup C'_q$, где $C'_q = f(C_q)$. При этом $S \in C_q \Leftrightarrow f(S) \in C'_q$. Преобразование f сжимающее, если $|X| < |S|$.

Последовательности стандартных преобразований

Рассмотрим последовательность преобразований $\{f_p\}$, где $p = 1, 2, \dots$, $f_p: X_{p-1} \rightarrow X_p$, $X_p = \{x_p\}$ – множество p -ых описаний из S , $x_p = f_p(x_{p-1})$, $X = X_0 = f_p(S)$ – множество начальных стандартных

описаний из S .

Последовательность преобразований $\{f_p\}$ стандартная, если f_p – стандартное для каждого p . Определим последовательность преобразований $\{F_p : X \rightarrow X_p\}$: 1) $F_0(x) \equiv f_0(x)$; 2) $F_p(x) \equiv f_p(F_{p-1}(x))$ при $p \geq 1$. Если $\{f_p\}$ – стандартная, то 1) для каждого p множество X_p является множеством стандартных описаний объектов из S ; 2) для каждого p можно однозначно определить функцию $y_p : X \rightarrow Q$, которая каждому $x_p \in X_p$ однозначно ставит в соответствие номер класса, в котором содержатся все элементы из $F_p^{-1}(x_p)$. При $p=0$ полагаем $y_0(x) = y(x)$. Из определения функции $y_p(x_p)$ следует, что $y(x) \equiv y_p(F_p(x))$.

Последовательность $\{f_p\}$ – сжимающая, если f_p – сжимающее для каждого p . Если $\{f_p\}$ – стандартная и сжимающая, то при некотором натуральном L для любого $q \in Q$ верно равенство $F_L^{-1}(x_{Lq}) = C_q$, где $X_L = \{x_{L0}, \dots, x_{L, Q-1}\}$.

Определим последовательность $\{f_p\}$ с главными элементами. В ней для каждого p первый элемент $f_{p1}(x_{p-1})$ является *главным* и принимает значения в Q ; остальные элементы $f_{p\ell}(x_{p-1})$, где $\ell = 2, 3, \dots$, являются вспомогательными.

Стандартная последовательность $\{f_p\}$ *частично корректная*, если для каждого p существует хотя бы одно $x_p \in X_p$, такое что $|X_{p-1}(x_p)| > 1$, где $X_{p-1}(x_p) = f_p^{-1}(x_p)$, и $f_p(X_{p-1}(x_p)) = const$.

Если стандартная последовательность $\{f_p\}$ с главными элементами – частично корректная, то 1) $\{f_p\}$ – сжимающая; 2) $F_L = (F_L)$ при некотором L и $y(x) \equiv F_L(x)$ на X .

Таким образом, стандартная частично корректная последовательность $\{f_p\}$ с главными элементами сходится, т.е. на некотором шаге L она дает искомую функцию $y(x) = F_L(x) = f_L \circ f_{L-1} \circ \dots \circ f_1(x)$.

При определенных условиях для построения стандартных частично корректных преобразований можно использовать конструктивные методы обучения алгебраических $\Sigma\Pi$ -нейронов и $\Sigma\Pi$ -нейромодулей [3,4] или их обобщений – алгебраических $\Sigma\Phi$ -операторов [5]:

$$\mathbf{sfn}(x) = \mathbf{out}(\mathbf{sf}(x)),$$

где $\mathbf{out}(\mathbf{x}) = (\text{out}_1(\mathbf{x}), \dots, \text{out}_m(\mathbf{x}))$ – решающее преобразование,
 $\mathbf{sf}(\mathbf{x}) = (\text{sf}_1(\mathbf{x}), \dots, \text{sf}_m(\mathbf{x}))$,

$$\text{sf}_j(\mathbf{x}) = \theta_j(\mathbf{x}) + \sum_{k=1}^N w_{jk} \Phi_{jk}(\mathbf{x}),$$

$\theta_j(\mathbf{x})$ – произвольная начальная функция, w_{j1}, \dots, w_{jN} – веса, $\{\Phi_{jk}(\mathbf{x})\}_{k=1, \dots, N}$ – последовательность функций, который на обучающем множестве входных векторов $\{\mathbf{x}_k\}_{k=1, \dots, N}$ удовлетворяет одному простому требованию [4,5].

Показано, например, что при некоторых предположениях можно построить сжимающую частично корректную последовательность преобразований $\{f_p(\mathbf{x}_p)\}$, где $f_p(\mathbf{x}_p)$ является $\Sigma\Phi$ -оператором и

содержит не более $M > Q + 1$ слагаемых, такую что $L \leq \left[\frac{|\mathbf{X}| - 1}{M - Q} \right] + 1$ [5].

Литература

1. Журавлев Ю.И. Проблемы кибернетики. М.: Наука. 1978. Вып. 33 – С. 5-68.
2. Журавлев Ю.И. Избранные научные труды. М.: Магистр. 1998. – 420 с.
3. Шибзухов З.М. Рекуррентный метод конструктивного обучения некоторых сетей из алгебраических $\Sigma\Pi$ -нейронов и $\Sigma\Pi$ -нейромодулей // Журнал ВМиМФ. 2003. Т. 43, № 8. – С. 1298–1310.
4. Шибзухов З.М. Корректные $\Sigma\Pi$ -расширения одного допустимого класса алгоритмов // Доклады РАН. 2004. Т. 394, № 4. – С. 462–464.
5. Шибзухов З.М. О последовательностях $\Sigma\Phi$ -расширений конечных множеств некорректных распознающих алгоритмов // Доклады РАН. 2005. Т. 402, № 5. – С. 609–612.

Мера близости в системе вывода на основе прецедентов

В.Н. Юдин

(Москва)

Введение

Вывод на основе прецедентов (Case Base Reasoning) – это метод принятия решений, в котором используются знания о предыдущих ситуациях или случаях (прецедентах). Решение, выбранное из наиболее подходящего прецедента (аналога), либо используется прямо, либо адаптируется к текущему случаю.

Наиболее популярным и часто используемым методом в выборе наиболее подходящих прецедентов является «метод ближайшего соседа». В его основе лежит тот или иной способ измерения степени близости

прецедента и текущего случая. Эта степень основывается на понятиях схожести случаев, которые, в свою очередь, базируются на знаниях о предметной области.

Методы добычи данных (Data Mining) могут оказаться полезными при автоматическом отборе из большой базы прецедентов или при адаптации решения к текущему случаю. В [1] описывается статистический критерий отбора прецедентов из базы, представленной моделью в виде Байесовской сети. Вычисляется распределение вероятностей прецедентов по значениям атрибутов, которые не совпадают со значениями атрибутов текущего случая, и выбирается тот прецедент, который имеет наибольшую вероятность.

Одним из способов определения меры близости является разбиение прецедентов на классы. Тогда близкими текущему случаю будут считаться прецеденты того же класса. В системе M^2 [2] база прецедентов предварительно разбивается на кластеры. Кластеры соответствуют различным внутренним понятиям базы и, соответственно, предполагают различные решения. Если текущий случай попадает в кластер, типичным аналогом для него считается центр кластера.

Недостаток такого метода кроется в том, что во многих приложениях набор атрибутов не фиксирован, и полного дифференцирования кластеров часто добиться не удастся. Распространены ситуации, в которых текущий случай попадает в область пересечения, в частности, когда он принадлежит нескольким понятиям сразу. Так, в медицине разные наборы признаков могут быть не только у разных заболеваний, но и в разных случаях одного и того же заболевания, вводимых в систему как прецеденты. И, наконец, пациент может иметь набор показателей, не полностью совпадающий с наборами признаков заболеваний, введенных в систему. В предлагаемом подходе эти недостатки преодолеваются, т.к. в нем изначально учтена специфика работы с нефиксированным набором атрибутов. Введено понятие близости для отбора прецедентов, базирующееся на понятии пересечения кластеров. Подход реализован на базе исследовательского программного комплекса, разработанного в Институте системного программирования РАН.

Метод

База прецедентов подвергается предварительной обработке (кластеризации) в пространстве, сформированном на основе всех встречающихся атрибутов прецедентов, с целью образовать основные понятия. При поиске аналогов для текущего случая, набор атрибутов которого, вообще говоря, не совпадает с общим набором, точка текущего случая сравнивается с пространственным расположением этих кластеров в проекции на подпространство его атрибутов. Близкими считаются прецеденты, принадлежащие кластеру, в который попадает случай. Если

он попал в область пересечения кластеров, то ближайшими к нему будут считаться прецеденты, также находящиеся в области пересечения. В зависимости от сложности пересечения, мы можем разделить их на группы с разной степенью близости (рис. 1). Прецеденты, находящиеся в одной с текущим случаем области пересечения, естественно, будут более близкими к нему, чем те, что находятся только в одном из кластеров. Смысл аналогов, находящихся в области пересечения, заключается в том, что с таким же набором атрибутов, что и текущий случай, они подобны ему по принадлежности к понятиям, обозначаемым кластерами.




Рис. 1. Степени близости прецедентов.

При адаптации решения от найденного аналога к текущему случаю используют разные методы, в зависимости от приложения. В некоторых случаях можно обойтись заменой некоторых компонентов в имеющемся решении или изменением порядка операций в нем. Но невозможно подобрать единый рецепт, который был бы одинаков для различных приложений. Дело в том, что автоматизация процесса адаптации является очень сложной задачей и пока практически не поддается обобщению.

Когда текущий случай попадает в пересечение кластеров, использование типовых решений от каждого из них не всегда приемлемо. В медицине прецеденты с несколькими заболеваниями могут иметь специфическое решение, отличающееся от типового. Кроме того, лечение одного заболевания в некоторых случаях может быть несовместимо с лечением другого. Предложенный метод, когда наиболее информативными считаются прецеденты из той же области пересечения, что и текущий случай, может оказаться полезным в подобных ситуациях.

Приведем пример. При сочетании двух патологий у одного больного (поражение сонных артерий, приводящее к инсульту, и вазоренальная гипертензия из-за стеноза почечных артерий) важно определить этапы оперативного лечения. При первом поражении проводят реконструктивную операцию на сонных артериях, при втором – на почечных. Для исключения риска кровоизлияния в головной мозг

начинают с реконструкции почечных артерий. Но головной мозг пациента, недостаточно снабжаемый кровью вследствие сужения сонных артерий, может не выдержать снижения артериального давления до нормальных цифр, вследствие чего разовьется ишемический инсульт. Поэтому проводят так называемую «гипотензивную пробу» - снижение артериального давления ближе к нормальным цифрам под контролем. Если пациент не выдерживает ее, то в первую очередь устраняют сужение сонных артерий. Подсказать врачу правильную тактику лечения больного может соответствующий прецедент (реальный или смоделированный). Существует реальный случай, когда пациенту на первом этапе была выполнена реконструкция почечных артерий, после чего последовала смерть больного. Следует заметить, что этот случай не является типовым прецедентом, т.е. моделью лечения. Более того, необходимое исследование (гипотензивная проба) не проводилось. Основную информацию для выбора решения из этого аналога врач почерпнет из комментария к результату лечения.

Заключение

Проблема выбора подходящего аналога является важной в системах вывода на основе прецедентов. В предлагаемом подходе описан вариант применения для такого выбора одного из методов Data Mining - кластеризации. Введенная мера близости, основанная на понятии пересечения кластеров, применима к широкому кругу приложений. Она не накладывает ограничения на типы используемых атрибутов. Учтена специфика работы с нефиксированным набором атрибутов. Допускается работа в условиях неполного описания случаев.

Литература

1. Torgeir Dingsøy Integration of Data Mining and Case-Based Reasoning // <http://www.idi.ntnu.no/~dingsoyr/diploma/>
2. Anand S.S., Patterson D.W., Hughes J.G., Bell D.A. Discovering Case Knowledge Using Data Mining // 2nd Pacific-Asia Conference in Knowledge Discovery in Databases (PAKDD-98), Australia, pp25-35, 1998.
3. Yudin V.N. Applying Cluster Analysis for Searching for Analogs in Diagnostics and Choice of Treatment // Pattern Recognition and Image Analysis, Vol. 13, No. 4, 2003, pp. 706–713.

Ускоренный алгоритм удаления поглощающих строк в булевой матрице и его применение в задачах распознавания образов

А.Е. Янковская
(Томск)

Введение

В задачах распознавания, классификации, поиска закономерностей [1, 2] одним из ключевых алгоритмов является алгоритм удаления поглощающих строк в булевой матрице, требующий существенных затрат при больших размерах булевой матрицы. В связи с этим актуальность построения эффективных реализаций алгоритма не вызывает сомнения.

Поскольку независимо от используемого алгоритма удаления поглощающих строк из булевой матрицы будет получена безызбыточная матрица одной и той же размерности, то эффективность алгоритма определяется только вычислительными затратами.

Предлагается ускоренный алгоритм удаления поглощающих строк в булевой матрице большой размерности, существенно сокращающий число переборов, описывается иллюстрирующий пример и области применения.

Постановка задачи, определение, теорема

Постановка задачи. Задана булева матрица U размерностью nm , где n – число строк, а m – число столбцов. Необходимо построить безызбыточную матрицу U' путем удаления из матрицы U поглощающих строк.

Определение. Булев вектор a поглощает булев вектор b , если все компоненты вектора a , соответствующие единичным компонентам вектора b , также имеют значение 1.

Теорема. Удаление единичных и нулевых столбцов в матрице U не влияет на результат поглощения (число поглощающих строк).

Доказательство очевидно.

Ускоренный алгоритм удаления поглощающих строк в булевой матрице

1. Удаление из матрицы U единичных и нулевых столбцов (построение матрицы U^*)
2. Подсчет числа единичных значений в строках матрицы U^* и упорядочивание строк по числу единичных значений (секционирование ее по неубыванию числа единичных значений в строках матрицы U^*) т.е. построение секционированной матрицы U^{**} .
3. Приведение подобных в матрице U^{**} , т.е. удаление в каждой секции матрицы U^{**} равных строк за исключением одной (построение матрицы U^-).
4. Построение матрицы U^+ путем проверки на поглощение строками из последующей секции матрица U^- строк из предыдущих секций (2-ю

секцию с 1-й, далее 3-ю со 2-й и 1-й и т.д.) с одновременным удалением поглощающих строк из матрицы U^- .

5. Включение в матрицу U^+ ранее удаленных (пункт 1) единичных и нулевых столбцов, т.е. построение матрицы U' .

Дальнейшее сокращение переборного процесса может быть достигнуто путем группировки в каждой секции булевой матрицы строк, содержащих единичное значение, начиная с левого столбца, и разбиения каждой секции на подсекции, содержащих единичное значение в левом столбце подсекции. При этом необходима только проверка на поглощаемость в одноименных подсекциях (по расположению левых столбцов) разных секций.

Иллюстративный пример

Поскольку рамки доклада не позволяют в полной мере проиллюстрировать весь алгоритм, остановимся на иллюстрации пункта 4, существенно влияющего на ускорение алгоритма, предварительно отметив, что исходная матрица U имела размерность 23×14 .

Пусть построена матрица U^- , состоящая из 4-х секций (рис. 1).

$$U^- = \begin{array}{l}
 \begin{array}{cccccccc|c}
 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & \\
 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & + \\
 2 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & + \\
 3 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & + 1 \\
 4 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & + \\
 5 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & + \\
 6 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & - \\
 7 & 1 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & - 2 \\
 8 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & - \\
 9 & 0 & 0 & 1 & 0 & 0 & 1 & 1 & 0 & + \\
 10 & 1 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & - \\
 11 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 1 & - 3 \\
 12 & 0 & 1 & 0 & 1 & 0 & 1 & 1 & 0 & - \\
 13 & 1 & 0 & 0 & 1 & 0 & 1 & 1 & 0 & - \\
 14 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & - 4 \\
 15 & 0 & 1 & 1 & 0 & 0 & 0 & 1 & 1 & + \\
 16 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 1 & +
 \end{array}
 \end{array}$$

$$U^+ = \begin{array}{l}
 \begin{array}{cccccccc|c}
 1 & 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & \\
 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\
 2 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 2 \\
 3 & 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 3 \\
 4 & 0 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 4 \\
 5 & 0 & 1 & 0 & 1 & 0 & 0 & 0 & 0 & 5 \\
 6 & 0 & 0 & 1 & 0 & 0 & 1 & 1 & 0 & 9 \\
 7 & 0 & 1 & 1 & 0 & 0 & 0 & 1 & 1 & 15 \\
 8 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 1 & 16
 \end{array}
 \end{array}$$

Рис. 1 Матрицы U^- , U^+ .

Справа от матрицы U^- удаляемые строки отмечены символом «-», а оставшиеся – символом «+». При проверке на поглощаемость строк матрицы U^- из 2-ой секции со строками из 1-ой секции удаляются 6, 7, 8-я строки; строк из 3-ей секции со строками 1-й секции и 9-ой строкой из 2-й секции удаляются все (10-12) строки 3-й секции и, наконец, при проверке строк 4-й секции со строками из 1-й секции удаляются 13, 14-я строки 4-й секции. В результате построена матрица U^+ (рис. 1).

Таким образом, даже на небольшом примере видно, что существенно сокращаются переборные процессы за счет целенаправленного перебора и отсутствия необходимости двойной проверки на поглощаемость (а

поглощает \mathbf{b} , и наоборот). При использовании алгоритма удаления поглощаемых строк, вместо 240 проверок на поглощаемость [3], необходимо при применении ускоренного алгоритма 62 проверки. Заметим, что на число проверок влияет первоначальное расположение строк в исходной матрице и оно может быть менее 240, но больше 128 по алгоритму [3].

Области применения

Ускоренный алгоритм удаления поглощающих строк из булевой матрицы применим для широкого круга задач, решение которых связано с поиском кратчайших и безызбыточных покрытий булевых матриц [3], с построением и выбором тестов в тестовых методах распознавания образов [1, 2], при проектировании дискретных устройств [2, 3] (минимизации числа состояний автоматов, противогоночном кодировании внутренних состояний асинхронных автоматов, минимизации системы булевых функций, построении логической схемы, разбиении и покрытии схем, построении тестов, моделировании, размещении, трассировки), а также с интеллектуальным анализом данных и знаний, с технической и медицинской диагностикой.

Заключение

Ускоренный алгоритм удаления поглощающих строк в булевой матрице реализован в интеллектуальном инструментальном средстве ИМСЛОГ [4], являющемся интегрированной средой разработки интеллектуальных систем выявления закономерностей в данных и знаниях и принятия решений для широкого круга проблемных областей.

Результаты испытаний алгоритма на тестовых и реальных булевых матрицах показали достаточно высокую эффективность алгоритма.

Работа поддержана РФФИ, проект № 04-01-00144.

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. – М.: Радио и связь. – 1990. – С. 149-190.
2. Янковская А.Е. Логические тесты и средства когнитивной графики в интеллектуальной системе// Новые информационные технологии в исследовании дискретных структур. Доклады 3-ей Всероссийской конференции с международным участием. – Томск: Изд-во СО РАН, 2000. – С. 163-168.
3. Закревский А.Д. Алгоритмы синтеза дискретных устройств. - М.: Наука, 1971.
4. Yankovskaya A.E., Gedike A.I., Ametov R.V., Bleikher A.M. IMSLOG-2002 Software Tool for Supporting Information Technologies of Test Pattern Recognition// Pattern Recognition and Image Analysis. – 2003. – Vol. 13. – No. 4. – P. 650-657.

II. Прикладные задачи и системы распознавания

Объектно-ориентированный анализ и проектирование многоуровневой системы классификации

Е.Н. Амиргалиев

(Алматы)

В данной работе рассматриваются вопросы анализа и проектирования информационной системы классификации, основанные на концепциях объектно-ориентированного анализа и проектирования. На первом уровне задача классификации решается известными алгоритмами классификации, так и модифицированными. На втором уровне используются алгоритмы группового синтеза. Оптимизационные процедуры проводятся как на первом уровне так и на втором. Таким образом, математические методы распознавания образов, объектно-ориентированные CASE-средства и соответствующие программно-технические средства составляют полную среду разработки информационной системы классификации..

Основная задача распознавания

Пусть задана начальная информация I , $\{S\}$ - множество допустимых объектов и каждый объект $S_i \in \{S\}$, $i=1, \dots, m$, характеризуется n - мерным вектором, координаты которого называются признаками, т.е. $S_i = (\alpha_{i1}, \alpha_{i2}, \dots, \alpha_{in})$, $i=1, \dots, m$, n - число признаков, $\alpha_{ij} \in M_j$.

Задача классификации:

$$A\{I(S), S\} = \bigcup_{j=1}^l K_j, K_i \cap K_j = \emptyset,$$

если $i \neq j$, $K_i \neq \emptyset$, $i, j=1, 2, \dots, l$.

При построении алгоритмов по принципу минимума расстояния,

В рамках системы также рассматривается возможность решения задачи группового синтеза классификаций для исходных алгоритмов, которая состоит в следующем.

Пусть $A_1, \dots, A_m \in \{A\}$ - исходный, заданный, набор алгоритмов и $M = \{S_1, \dots, S_n\}$ - конечное множество объектов, $M \subset D$. Результатом применения A_i к M являются классификации $K_i(M) \in \mathfrak{R}(M)$. Основная задача группового синтеза состоит в

следующем. Пусть определена метрика $d(K, K_1)$ в $\mathfrak{R}(M)$ и

$$\phi(K) = \sum_{i=1}^m d(K, K_i), \quad K \in \mathfrak{R}(M). \text{ Найти } K^*(M) \in \mathfrak{R}(M) \text{ такую,}$$

$$\text{что } \phi(K^*) = \min_{K \in \mathfrak{R}(M)} \phi(K).$$

Объектно-ориентированное проектирование

Объектно-ориентированный подход использует объектную декомпозицию, при этом статическая структура системы описывается в терминах объектов и связей между ними, а поведение системы описывается в терминах обмена сообщениями между объектами. Каждый объект системы обладает своим собственным поведением, моделирующим поведение объекта реального мира.

Концептуальной основой объектно-ориентированного подхода является *объектная модель*. Определение объектов и классов является основной задачей объектно-ориентированного подхода.

Важным качеством объектного подхода является согласованность моделей проектируемой системы от стадии формирования требований до стадии реализации. Требование к системе описывается диаграммами прецедентов.

На первом этапе проектирования выделим основной принцип работы всей системы.

Функциональная схема включает в себе следующие прецеденты:

Подсистема управления общей работой системы; Справочная подсистема; Подсистема предварительной обработки информации и определения информативности признаков; Подсистема реализации алгоритмов классификации; Алгоритмы группового синтеза; Подсистема работы с базой данных; Подсистема анализа устойчивости и достоверности решения; Подсистема визуализации результатов; Подсистема ГИС;

Каждая подсистема реализуется множеством алгоритмов и процедур.

На рис. 1 приведена диаграмма прецедентов подсистемы «Управление». Такой набор диаграмм применяется в целях определения требования для каждой подсистемы. По мере необходимости диаграмма детализируется.

Например, подсистема «Справка- Help». Данный блок представляет собой независимую систему справочной информации, содержащей в себе сервисы присущие справочным системам любого программного продукта. В данной подсистеме описаны назначения функциональных блоков системы, схемы управления системой, а также характеризуются параметры настройки алгоритмов. Пользователь может воздействовать на справочную подсистему для вывода интересующей его информации по работе с системой. Помимо всего прочего система поддерживает ряд

сервисов: продолжить работу, редактирование БД, анализ данных с помощью всех блоков системы, проходящие через сервис «Сохранить результаты»; определение статуса пользователя; возможности связи с другой системой.

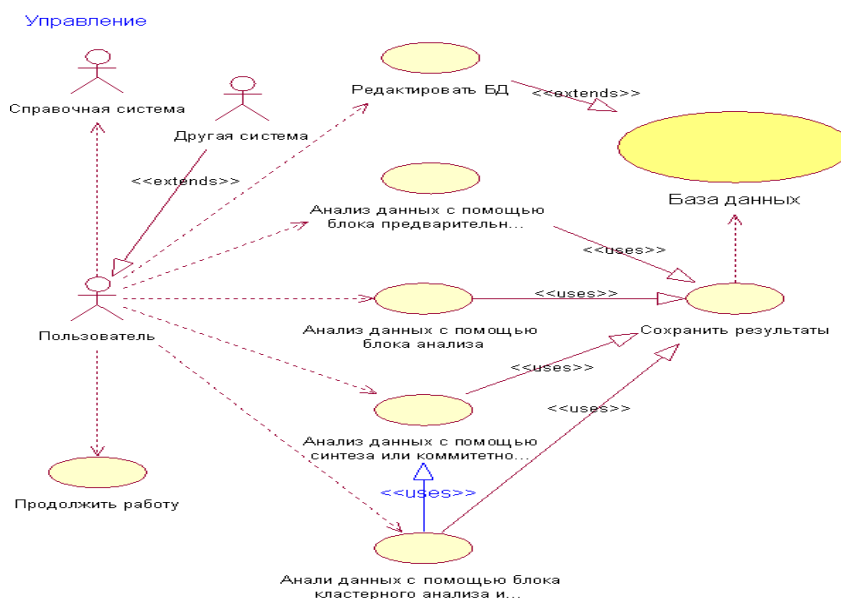


Рис.1. Диаграмма прецедентов подсистемы «Управление».

Таким образом, в данной работе рассмотрены вопросы проектирования некоторых модулей информационной системы на основе методов и моделей распознавания образов и классификации, предназначенные для анализа многомерных данных. Рассмотренная концепция построения информационной системы может быть использована в разных предметных областях, для решения реальных задач. Для проектирования данной системы был использован язык UML и объектно-ориентированная среда проектирования Rational Rose. Вне нашего внимания, к сожалению, остались многие аспекты разработки, поддерживающие концепции языка UML

Литература

1. Уэнди Боггс Rational Rose & UML. – М.: «Издательство Лори», 1999г.
2. Амиргалиев Е.Н. Методы распознавания образов и кластерного анализа. Учебник, Алматы, КазНТУ имени К.И.Сатпаева, 2003.
3. Вендров А.М. Проектирование программного обеспечения ЭИС. –М.: 2000г.

Определение тональности музыкальных произведений

С.А. Андреевко, С.А. Борисов

(Москва)

Введение

В традиционной европейской музыке важную роль играет понятие тональности. Тональность задает смысловые соотношения между конкретными звуками (например, нота «ля» имеет разный смысл в тональностях «Ля мажор» и «Ре мажор») и является характеристикой целого произведения или достаточно протяженной его части [1]. Понятие тональности применимо к широкому спектру музыкальных произведений, от классической музыки до современных танцевальных стилей, поэтому задача автоматического определения тональности является важной частью компьютерного анализа и распознавания музыки.

Во многих случаях существенной характеристикой ноты является не ее абсолютная высота, а функция, которую она выполняет в данной тональности. Эта функция называется степенью лада, и определяется разностью высот между данной нотой и тоникой (основной нотой тональности). Основные ступени лада обозначаются римскими числами от I (тоника) до VII.

Мы ограничимся рассмотрением натурального мажора и минора, а также не будем различать энгармонически равные тональности, поскольку различие между ними в записанной композиции не существует. Таким образом, остается 24 тональности, по одной минорной и одной мажорной на каждой ступени хроматической гаммы.

Методы и результаты

Предлагаемый подход основан на рассмотрении статистики высот нот, составляющих произведение. При этом учитывается лишь степень лада, соответствующая данной ноте, а не абсолютное значение высоты.

Нами была отобрана коллекция из нескольких десятков композиций разных жанров в формате MIDI, имеющих определенную тональность (мажорную или минорную, приблизительно в равной пропорции). Прежде всего, была посчитана средняя (по всем композициям) доля нот, соответствующих каждой ступени лада - на рисунке 1 представлено распределение ступеней для мажорных тональностей:

Как и следовало ожидать, чаще всего встречаются ступени, соответствующие тоническому трезвучию (I, III, V). Наиболее редко – ступени, не входящие в трезвучия тоники, субдоминанты и доминанты (I#, II#, IV#, V#, VI#) – в До-мажоре это черные клавиши фортепиано.

Этого уже достаточно для определения тональности – мы можем найти наилучшее соответствие между распределением нот неизвестной композиции и эталонными распределениями для каждой тональности. Однако эту оценку можно существенно улучшить, если учесть, что

отклонения от средних значений коррелированы – это соответствует природе музыки (локальные модуляции в другие тональности, и т.д.).




Рис 1. Распределение нот по ступеням мажорного лада.

Мы предлагаем использовать для этого метод анализа главных компонент. В 12-мерном пространстве строится «облако» из точек, соответствующих распределениям нот по ступеням для каждой эталонной композиции, и поочередно вычисляются ортогональные направления максимальной дисперсии получившегося облака. Анализ соответствия распределения нот неизвестной композиции с учетом метрики, учитывающей «форму» облака, позволяет улучшить определение тональности. Кроме того, как побочный результат получают вектора типичных отклонений от средних значений распределения, ассоциированные с гармоническими и тональными вариациями, могущие представлять интерес с точки зрения теории музыки.

Стоит отметить, что примененная схема достаточно устойчива, и работает как для полностью корректной MIDI композиции, так и для MIDI данных, полученных на выходе автоматических систем распознавания музыки (например, [2]), которые содержат существенное число неверных нот. Точность определения несколько ухудшается (типичной ошибкой является определение тональности доминанты), но остается достаточной для практических применений.

Литература

1. Вахромеев В. Элементарная теория музыки // Музыка. Москва 1995. С. 105-136.

Итерационный способ последовательного перехода от метода Монте-Карло к диффузионному приближению в оптическом изображении биологических сред

А.Ю. Анпанов, Ю.Н. Барабаненков, Ю.В. Обухов

(Москва)

Введение

Метод зондирования биологических сред путем отражения узкого коллимированного светового пучка имеет широкие приложения в биооптике. В этом методе узкий коллимированный пучок света падает на поверхность биологической среды. Излучение распространяется в объеме рассеивающей среды и диффузно отраженное излучение измеряется на некотором расстоянии вдоль поверхности от точки падения пучка. Важно подчеркнуть, что согласно экспериментальным работам [1] распространение света в среде происходит по «путям», которые распределены под поверхностью среды на определенной глубине и занимают область некоторого оптического информационного канала, имеющего форму «банана», с концами около точек источника и приемника светового излучения на поверхности среды. На рис. 1 дается иллюстрация подобного рода информационного канала при определении насыщения крови головного мозга человека кислородом (оксигенация) [2].

Метод Монте-Карло и диффузионное приближение

Распределение диффузно отраженного излучения пучка вдоль поверхности среды и параметры банана могут быть рассчитаны [3] с помощью традиционного диффузионного приближения в теории переноса излучения (ТПИ) [4]. Однако это приближение не всегда обеспечивает достаточную точность. В ряде работ (см. например, [5]) для решения поставленной проблемы о распределении интенсивности диффузно отраженного пучка вдоль поверхности используется стандартный метод Монте-Карло (МК) для ТПИ. Однако, метод МК носит статистический характер и требует больших затрат машинного времени.

Комбинированный (гибридный) метод

Мы исходим из обычного уравнения переноса излучения в рассеивающей среде [4] для лучевой интенсивности $I(\vec{r}, \vec{s})$ в точке \vec{r} и в направлении единичного вектора \vec{s} . Решение уравнения переноса может быть записано в терминах функции Грина $G(\vec{r}, \vec{s}; \vec{r}', \vec{s}')$ и заданного источника излучения $Q(\vec{r}, \vec{s})$ как $I = GQ$. Записывая интегральное уравнение для функции Грина с учетом ее свойства взаимности и решая

это уравнение итерационным способом, мы получаем для лучевой интенсивности внутри рассеивающей среды следующее операторное представление:

$$I = I^{(0...N)} + GQ^{(N+1)} \quad (1)$$





Рис. 1. Оптический информационный канал. Рис.2. Комбинированный метод

Здесь первый член $I^{(0...N)}$ содержит кратности рассеяния от 0 до N , где $N=1,2,3...$. Величина $Q^{(N+1)}$ обозначает плотность эффективного источника, соответствующая кратности рассеяния N и определяется уравнением $Q^{(N+1)} = \Sigma I^{(N)}$. В правой части этого уравнения величина $\Sigma(\vec{s}, \vec{s}')$ - сечение рассеяния элементарного объема рассеивающей среды, при вычислениях G заменяется на стандартное диффузионное приближение G_{diff} .

Результаты

Рассмотрим полуограниченную среду с коэффициентом рассеяния $\mu_s=54 \text{ см}^{-1}$, фактором анизотропии (средний косинус угла элементарного акта рассеяния) $g=0.7$, коэффициентом поглощения $\mu_a=0.01 \text{ см}^{-1}$, что моделирует биологическую рассеивающую среду в виде интралипидной эмульсии. На рис. 3 и 4 приводятся профили интенсивности выходящего излучения $R(r)$, вычисленные с помощью уравнения (1) для значений кратности рассеяния $N=0$ и $N=10$; r обозначает расстояние вдоль поверхности среды от точки падения пучка. На этих же рисунках для сравнения приведены результаты численного моделирования распространения света в среде с помощью метода МК [5] с реализацией 10^7 фотонов. Случай $N=0$ соответствует традиционному диффузионному приближению в ТПИ [3,4]. Как видно из рисунка 3, традиционное диффузионное приближение дает существенно завышенное значение на малых расстояниях и заметно заниженное значение на больших расстояниях от точки падения пучка. В этом приближении не учитываются малые кратности рассеяния, описываемые первым слагаемым уравнения (1), и эффективный источник диффузионного приближения, представляемый выражением $Q^{(1)}$, сосредоточен в основном на отрезке $0 < z < 1 / (\mu_a + \mu_s)$ линии падающего пучка. С увеличением кратности

рассеяния N наблюдается повышение точности гибридного метода, который предполагает вычисление функции распределения $R(r)$ выходящего из среды излучения с помощью обоих членов правой части уравнения (1). Результаты вычислений функции распределения $R(r)$ с учетом кратностей рассеяния до $N=10$ включительно приведены на рис. 4 (см. Hybrid, $I^{(0..N)} + G_{diff}Q^{(N+1)}$).




Рис. 3. Диффузионное приближение ($N=0$) Рис. 4. Гибридный метод ($N=10$).

Относительная погрешность гибридного подхода на рассматриваемом интервале расстояний изменяется в пределах от -5% до $+5\%$.

Заключение

Предложен итерационный подход, позволяющий проследить в задаче об отражении узкого пучка света от рассеивающей среды последовательный переход от решения уравнения переноса излучения методом Монте-Карло к решению уравнения диффузии света в рассеивающей среде. Итерационным параметром этого подхода является кратность рассеяния светового излучения N .

Литература

1. Cui W., Kumar C., Chance B. Experimental Study of Migration Depth for the Photons Measured at Sample Surface, SPIE Time-Resolved Spectroscopy and Imaging of Tissues, 1991, vol. 1431, 180-191

2. Режим доступа: http://www.somanetics.com/invos_principles.htm
3. Barabanenkov Yu.N. and Kargashin A.Yu. Diffusion calculation of change of back-scattered light beam intensity from turbid medium owing to the existence of an inhomogeneity, *Journal of Modern Optics*, 1993, vol. 40, no. 11, 2243-2255
4. Исимару А. Распространение и рассеяние волн в случайно-неоднородных средах, т.1, 2. М.: Мир, 1981
5. Prahл S.A., Keijzer M., Jacques S.L., Welch A.J. A Monte Carlo model of light propagation in tissue, *SPIE Institute Series*, 1989, vol. IS5, 102-111

Метод иерархической компрессии индексных изображений с разбиением на цветовые плоскости

А.Ю. Баврина, Н.И. Глузов, В.В. Сергеев, Е.И. Тимбай
(Самара)

В работе предлагается метод безошибочной компрессии индексных изображений искусственного происхождения. Такими изображениями являются картографические изображения, полученные с помощью специализированных программных систем. Сжатие изображений позволяет уменьшить объем, требуемый для хранения данных, и сократить время передачи изображения по сети.

Так как количество цветов на картографических изображениях, как правило, невелико, изображение может быть разбито на цветовые плоскости. Одну из цветовых плоскостей сжимать и помещать в архив не нужно, так как точки этого цвета будут располагаться в местах, не заполненных точками остальных цветов. В качестве плоскости, отсутствующей в архиве, логично выбирать плоскость, занимающую наибольшую долю в архиве. Кроме того, для повышения эффективности работы алгоритма сжатия предлагается использовать взаимосвязи между плоскостями.

Сжатие каждой цветовой плоскости осуществляется с помощью метода иерархического сжатия индексных изображений [1], идея которого заключается в следующем. Изображение разбивается на блоки размером 2×2 . Составляется список, содержащий все различные четверки значений в блоках, упорядоченный по убыванию частоты встречаемости данной четверки на изображении. Матрица следующего иерархического уровня состоит из соответствующих индексов четверок в списке текущего уровня, причем четверки, встречающиеся один раз, кодируются одним индексом. Матрица старшего уровня и списки уровней подвергаются статистическому кодированию [2] и сохраняются в архиве.

Небольшая модификация метода иерархического сжатия позволяет при кодировании текущей плоскости учитывать информацию, содержащуюся на следующих кодируемых цветовых плоскостях.

Объекты на картографических изображениях можно условно подразделить на площадные и контурные. Если контур пересекает площадной объект, то на битовой плоскости площадного объекта в месте пересечения будет разрыв единичной области. Это будет мешать кодированию, так как с точки зрения иерархического метода однородные области кодируются лучше. Если последовательность обработки цветовой плоскости при декомпрессии такова, что контурная плоскость будет накладываться на восстанавливаемое изображение после площадной, то разрыв единичной области на площадной цветовой плоскости можно ликвидировать.

С точки зрения такого учета взаимосвязей между цветовыми плоскостями, наилучшим будет порядок обработки плоскостей, при котором сначала обрабатываются площадные слои в порядке убывания количества точек соответствующего им цвета, а затем контурные слои в порядке возрастания количества точек цвета. Первая плоскость, которая является площадной с наибольшим количеством точек цвета, не кодируется. Эффективность такого порядка обработки цветовой плоскости была подтверждена экспериментально.

Для оценки эффективности предложенного метода компрессии были проведены экспериментальные исследования на тестовых изображениях, полученных из цифровых карт. Разработанный метод иерархического сжатия индексных изображений на основе разделения на цветовые плоскости сравнивался с базовым вариантом (с адаптивным выбором порога), стандартами сжатия GIF [3] и JPEG-LS [4], методом компрессии на основе иерархической сеточной интерполяции [5] и архиватором WinZIP. Результаты сравнения по объему сжатых файлов относительно исходных изображений приведены в таблице 1.

Таблица 1. Результаты экспериментальных исследований на тестовом наборе из 14 изображений размера 1024×1024

	ZIP	GIF	JPEG-LS	HGI	Базовый вариант	С разделением на цветовые плоскости
Относительный объем, %	7,11	8,03	7,93	7,19	5,81	4,48

Как видно из таблицы, применение разделения на цветовые плоскости дает уменьшение объема сжатых данных на 22,9% относительно базового варианта.

Литература

1. Баврина А.Ю., Глумов Н.И., Сергеев В.В., Тимбай Е.И. Метод иерархической компрессии индексных изображений // Компьютерная оптика. Самара, 2005. Вып. 26. С. 125-129.

2. Langdon G.G. An introduction to arithmetic coding // IBM Journal of Research and Development. 1984. Vol. 28. No. 2. Pp. 135-149.
3. Мюррей Д., Ван У. Райпер Энциклопедия форматов графических файлов: пер. с англ. // К.: Издательская группа BHV. 1997. 672 с.
4. Marcelo Weinberger, Gadiel Seroussi, Guillermo Sapiro, Michael W. Marcellin The LOCO-I Lossless Image Compression Algorithm: Principles and Standardization into JPEG-LS // Hewlett-Packard Computer Systems Laboratory, HPL-98-193. November 1998.
5. Gashnikov M.V., Glumov N.I., Sergeev V.V. Information-Processing Technology of Image Compression for Real-Time Systems// Pattern Recognition and Image Analysis. 2003. Vol. 13. No. 2. Pp. 205-207.

Система прогнозирования потребительского спроса Goods4Cast

***О.В. Баринаова, А.С. Вальков, К.В. Воронцов, С.А. Громов, А.Н. Ефимов,
Ю.В. Чехович***
(Москва)

Задача прогнозирования потребительского спроса для розничной сети магазинов состоит в ежедневном построении прогнозов спроса на каждый товар из ассортимента каждого магазина сети. Прогнозы спроса используются при планировании закупок, планировании промо-акций (рекламных кампаний), управлении ценами и ассортиментом.

Данная прикладная задача имеет ряд существенных особенностей, накладывающих определённые ограничения на методы решения.

1. Количество прогнозируемых временных рядов имеет порядок 10^7 – 10^8 , при этом расчет прогнозов должен занимать не более нескольких часов. Проблема не может быть решена простым наращиванием вычислительных мощностей, требуется высокая скорость вычисления прогнозов и настройки алгоритмов прогнозирования.

2. Статистические характеристики временных рядов продаж существенно различны для разных товаров. Штучным товарам соответствуют дискретные ряды, весовым товарам — вещественные. Существуют товары, устойчиво продающиеся каждый день, однако подавляющее большинство товаров продаются не чаще, чем раз в неделю.

3. Прогнозируемые ряды не являются стационарными. Они могут претерпевать значительные разовые всплески (многократные изменения продаж во время промо-акций или праздников), либо, наоборот, падения до нуля (временное прекращение поставок). Они могут претерпевать как резкие, так и плавные изменения статистических характеристик, связанные с вытеснением одних товаров другими, изменением режима поставок, и другими факторами.

4. Завышение и занижение прогнозов приводят к различной величине

потерь. Поэтому строить критерий качества прогнозирования на основе стандартной квадратичной функции потерь нецелесообразно.

5. Требуется прогнозировать временной ряд спроса, хотя наблюдается временной ряд продаж. Отсутствие продаж может быть вызвано не только отсутствием спроса, но и другими причинами: отсутствием товара на складе, недоступностью товара на полках, и т. д.

Перечисленными особенностями задачи продиктованы следующие особенности решения.

1. Для прогнозирования используются либо достаточно простые алгоритмы, время настройки которых не более чем линейно по длине ряда, либо динамически обучаемые (on-line) алгоритмы, параметры которых подстраиваются по мере поступления данных.

2. Поскольку такие алгоритмы прогнозирования являются, по сути дела, эвристическими и некорректными, используется техника построения алгоритмических композиций, основанная на идеях алгебраического подхода [3]. Для каждого временного ряда строится несколько альтернативных моделей алгоритмов. В простейшем случае из них выбирается алгоритм, дающий лучшее качество прогнозов по критерию скользящего контроля на последнем отрезке ряда. В более общем случае строится динамически адаптируемая композиция базовых алгоритмов [2]. Для каждого ряда в каждый момент времени наибольший вес получает наиболее адекватная модель. Это позволяет полностью автоматизировать построение прогнозов для большого количества нестационарных временных рядов, имеющих существенно различное поведение.

3. Перед настройкой алгоритмов производится фильтрация исторических данных. Из обучения исключаются интервалы аномально высоких и аномально низких продаж, связанные скорее с разовыми событиями, чем с регулярным спросом.

4. В качестве критерия настройки алгоритмов прогнозирования применяется неквадратичный несимметричный функционал потерь, оценивающий не абстрактную «точность прогноза», а величину потерь в рублях от завышенного или заниженного прогноза [1].

Рассматриваемые в докладе методы и подходы реализованы в автоматизированной системе прогнозирования потребительского спроса Goods4Cast. Данная система строит прогнозы для 140 магазинов и 250000 товаров. Время расчета прогнозов для одного магазина около 5 минут на рабочей станции 2×Xeon 3.2 ГГц, 3 Гб ОЗУ, 2×250 Гб raid.

Работа выполнена при поддержке РФФИ, проект № 04-01-08063-офи.

Литература

1. Барина О. В. Об одном методе прогнозирования временных рядов с несимметричным функционалом потерь // В настоящем сборнике. 2005.

2. Воронцов К. В., Егорова. Е. В. Динамически адаптируемые композиции алгоритмов прогнозирования // В настоящем сборнике. 2005.
3. Журавлев Ю. И. Корректные алгебры над множествами некорректных (эвристических) алгоритмов. I–III // Кибернетика, 1977. №4. С. 5–17, 1977. №6. С. 21–27, 1978. №2. С. 35–43.

Применение технологии Data Mining для прогнозирования исхода родов

О.Г. Берестнева, Р.Г. Добрянская, Е.А. Муратова
(Томск)

Введение

Общепризнанным является тот факт, что психогенные факторы способствуют нарушению биологической готовности к родам, но исследований в этом направлении недостаточно, как и попыток прогнозирования поведенческих реакций женщины в родах [1]. Во время беременности, особенно первой, происходят значительные изменения на соматическом, психологическом и социальном уровнях. Цели нашего исследования включали, во-первых, изучение особенности течения родов у женщин в зависимости от их психофизиологических особенностей и стратегий coping-поведения, во-вторых, разработку методов экспресс-диагностики для выявления «групп риска». Решение данных задач осуществлялось на основе технологии Data Mining [2], в том числе с использованием разработанных нами ранее методов и алгоритмов анализа данных [3-5].

Характеристика экспериментального материала и первичный анализ данных

Экспериментальное исследование проводилось на базе женской консультации родильного дома № 1 г. Томска. Было обследовано 236 беременных женщин в возрасте от 18 до 36 лет со сроками гестации от 4 до 38 недель, вынашивающих первого ребёнка. Одной из задач настоящего исследования было исследование влияния на исход беременности таких психологических факторов, как уровень стресса, представленность психической ригидности в структуре личности, особенности coping-стратегий у женщин, отличающихся по социальному положению (образование, семейный статус) и антропометрическим данным (рост, размеры таза, показатели кистевой динамометрии). Актуальность данной задачи обоснована в работах [6,7].

Психодиагностические показатели, использованные в исследовании подробно описаны в [7]. Представленность психической ригидности в структуре личности исследовалась с помощью Томского опросника ригидности Залевского (ТОРЗ), позволяющего оценивать актуальную (АР),

установочную (УР) и сенситивную ригидность (СР). Показатели по шкале АР характеризуют неспособность при объективной необходимости изменить мнение, отношение или установку. Шкала УР отражает личностный уровень проявления психической ригидности, выраженный в установке на принятие или непринятие нового, необходимости изменения самого себя, привычек. Шкала СР отражает эмоциональную реакцию человека на изменения в его жизни, страх перед новым (неофобии). Для определения уровня стресса применили проективную методику – метод цветowych выборов, модифицированный тест Люшера. Для исследования копинг-стратегий использовали копинг-тест Е.Нейн.

Наличие в экспериментальном материале количественных, порядковых и качественных признаков, необходимость их совместного анализа обусловило выбор в качестве инструментария методов Data Mining. На первом этапе были выявлены логические закономерности на базе пакета WizWhy и проведена оценка информативности признаков с помощью информационной меры Кульбака. Для построения прогностических моделей были выбраны методы построения деревьев решений (на базе пакета See5) и дискриминантного анализа. Во втором случае предварительно требовалось решить задачу унификации признакового пространства. Для решения ряда задач данного исследования была использована разработанная нами технологии конструирования диагностических шкал [4].

Технология конструирования диагностических шкал

Конструирование диагностической шкалы (ДШ) представляет собой процесс выделения граничных значений, образованных на основе частотного распределения значений исследуемого показателя в выборке стандартизации. Поиск новых подходов при конструировании ДШ в настоящее время в медицинских и психологических исследованиях особенно актуален, поскольку традиционная методология обладает рядом недостатков. Например, требуется формирование репрезентативной выборки стандартизации, а это в современных условиях предполагает большие трудовые, временные и финансовые ресурсы, и, кроме того, не всегда осуществимо в силу специфичности группы исследуемых. Кроме того, любые диагностические нормы, как бы они не выражались, всегда получены для определенной группы лиц или объектов, вследствие чего их нельзя считать постоянными. Нами разработан программный комплекс (ПК) UniData, реализующий адаптивный подход при выделении информативных интервалов [5].

Технология конструирования ДШ включает 3 группы алгоритмов выделения интервалов: равномерное, неравномерное, комбинированное. В программе предусмотрена возможность сравнения информативности

выделяемых интервалов с экспертными (или общепринятыми), если такие имеются в распоряжении исследователя.

В нашем исследовании технология конструирования ДШ была использована в качестве инструментария при изучении структуры экспериментальных данных и унификации признакового пространства. В первом случае, выявленные закономерности позволили объяснить существующие факты и процессы в изучаемой предметной области, обнаружить новые знания или переосмыслить ранее известные факты. Во втором случае, выделенные информативные интервалы рассматриваются в качестве новых бинарных признаков.

Заключение

Полученные в работе результаты позволили разработать программу дифференцированной психологической коррекции и психологической поддержки беременной женщины при освоении новой социальной роли матери.

Работа выполнена при финансовой поддержке РФФИ, проект № 04-06-80413

Литература

1. Абрамченко В.В. Психосоматическое акушерство. СПб.: СОТИС, 2001. 320 с.
2. Дюк В., Самойленко А. Data Mining: учебный курс. СПб: Питер, 2001. 368 с.
3. Янковская А.Е., Муратова Е.А., Берестнева О.Г. Применение локальных метрик для формирования и оптимизации базы знаний // 5-я международная конференция «Распознавание образов и анализ изображений: новые информационные технологии» (РОАИ-5-2000). Труды конференций в 4-х томах. Т. 4. Программно-аппаратные средства в системах распознавания образов и обработке изображений. Самара, 2000. С. 784-788.
4. Муратова Е.А., Берестнева О.Г. Применение технологии конструирования диагностических шкал в задачах психологии интеллекта // Труды международных научно – технических конференции «Интеллектуальные системы (IEEE AIS'04)» и «Интеллектуальные САПР» (CAD-2004). Научное издание в 3-х томах. М.: Изд-во Физико-математической литературы, 2004, Т.1. С. 223-228.
5. Янковская А.Е., Муратова Е.А., Берестнева О.Г. Эффективный алгоритм адаптивного кодирования разнотипной информации // Труды конгресса «Искусственный интеллект в XXI веке». – М.: ФИЗМАТЛИТ, 2001. – С. 155-167.
6. Добрянская Р.Г. Исследование стратегий преодоления эмоционального стресса у беременных женщин // Сибирский психологический журнал. 2003. №18. С. 65-67.

7. Добрянская Р.Г., Евтушенко И.Д., Залевский Г.В. Система дифференциальной медико-психологической помощи беременным женщинам /Методические рекомендации для врачей акушеров-гинекологов и психологов женских консультаций. Томск, 2005. 58 с.

Цифровой анализ электрокардиограмм

Н.М. Богатов, В.Ф. Гук

(Краснодар)

Электрокардиография (ЭКГ) является одним из основных инструментов медицинской диагностики. Получаемая с ее помощью информация о биоэлектрической активности сердца позволяет оценить состояние не только сердечно-сосудистой системы, но и организма в целом. Современные возможности компьютерной обработки сигналов позволяют быстро обрабатывать большие массивы данных. Сочетание этих возможностей и традиционных методов анализа ЭКГ позволяет создавать вычислительные кардиомониторы, решающие вопросы автоматического анализа временных и частотных параметров, хранения электрокардиограмм (в т.ч. сжатия и передачи), проводящих полный цикл обследования от накопления исходных данных до получения квалифицированного медицинского заключения.

Цель работы – создание программного обеспечения для автоматизированного распознавания и анализа электрокардиограмм в цифровом виде.

Электрокардиосигнал (ЭКС) относится к интерференционному электрофизиологическому процессу, так как образуется в результате пространственно-временного суммирования биопотенциалов различных биологических структур, и, следовательно, носит стохастический характер. Однако в норме моменты возникновения комплекса QRS, как правило, подчиняются нормальному закону распределения. Большинство методов анализа ориентировано на участки сигнала, среднее значение которых не меняется во времени, а автокорреляционная функция зависит только от разности временного параметра, поэтому нестационарность ЭКГ процесса не рассматривается. Стационарный процесс протекает примерно однородно и имеет вид непрерывных колебаний вокруг некоторого среднего значения. На ритм сердца оказывают постоянное воздействие центральная и вегетативная нервная системы, насыщение крови кислородом, различные рефлекссы. Все эти влияния относят к стационарным влияниям на ритм сердца. В тоже время существуют переменные факторы, связанные с функционированием системы кровообращения и дыхания, создающие в ЭКС нестационарную составляющую. Эти участки ЭКГ после выявления исключаются из анализа как артефакты.

Алгоритм разработанной программы содержит в себе следующие шаги, типичные для программ такого класса:

1. Подготовка входных данных: оцифровка, фильтрация и нормирование сигнала.
2. Распознавание характерных участков ЭКГ, имеющих диагностическое значение (комплексов QRS, PQ, QT и отдельных зубцов).
3. Анализ параметров и взаимосвязи распознанных участков и формирование оценочного заключения.

На первом этапе, как правило, трудностей не возникает. Фильтрация осуществляется как аппаратно, так и программно (во временной или частотной областях), а характеристики современных аналого-цифровых преобразователей позволяют избежать пропущенных кодов. На этапе распознавания ЭКГ присутствует ряд трудностей. Электрокардиосигнал квазипериодичен и последовательные кардиоциклы в точной мере никогда не повторяют друг друга, что обуславливает выбор методов распознавания. В настоящей работе предлагается использование двух методов: синтаксического и корреляционного [1].

При использовании синтаксического метода сначала выявляется локализация одного R-зубца поиском простого максимума, затем создается параметрическое описание (амплитуда, длительность переднего и заднего фронта) QRS-комплекса и далее производится сканирование всего исходного массива выборок на предмет локализации аналогичных похожих участков, являющихся другими QRS-комплексами. Метод показал хорошую устойчивость к колебаниям изолинии, однако ошибался при соизмеримости амплитуд R и T зубцов.




Рис. 1. Рабочее окно программы распознавания и анализа ЭКГ.

Корреляционный метод основан на измерении степени подобия (коэффициентов корреляции) эталонного образца фрагмента ЭКГ (зубца или комплекса зубцов) и фрагмента исследуемой ЭКГ той же размерности

при сканировании вдоль временной оси с шагом в один отсчет. В результате получаем массив коэффициентов корреляции, распределенных по временной оси сигнала ЭКГ, которые максимально приближаются к единичному значению в участках максимального сходства образца и фрагмента ЭКГ (рис. 1).

Литература

1. Солонина А.И., Улахович Д.А. и др. Основы цифровой обработки сигналов. СПб.: БХВ – Петербург, 2003. -608 с.

Моделирование и анализ изображений белковых комплексов тилакоидной мембраны

Н.М. Богданкевич, А.И. Чуличков

(Москва)

В настоящей работе морфологические принципы анализа изображений [1] применяются для решения задачи классификации изображений белковых комплексов тилакоидной мембраны. Одной из важных проблем при изучении процессов фотосинтеза является установление взаимного расположения белковых комплексов, встроенных в мембрану. Требуется определить количество классов белковых комплексов на заданном изображении большого числа различных белковых комплексов, а также выделить фрагменты, отвечающие комплексам из разных классов.

В работе построена математическая модель изображения белкового комплекса, формируемого электронным микроскопом, и разработаны алгоритмы анализа этих изображений.

Известна технология получения изображения белкового комплекса. Исследуемый фрагмент мембраны замораживается, затем раскалывается. На поверхность скола напыляется металл под некоторым фиксированным углом. Затем мембрана удаляется, после чего получают изображение металлической пленки в просвечивающем электронном микроскопе. Белковые комплексы одного типа могут быть различно ориентированы относительно направления напыления. Поэтому изображения как таковые (как распределение яркости по фрагменту поля зрения) сравнивать не имеет смысла. В данной работе построена математическая модель изображений белковых комплексов, на основе которой можно решать задачу классификации независимо от ориентации комплекса относительно направления напыления.

Для решения задачи классификации предлагается использовать подходы, известные в морфологическом анализе изображений [1]. Методы морфологического анализа позволяют описывать изображения и объекты в терминах, не зависящих от условий регистрации.

Моделирование изображения белкового комплекса

В работе строится достаточно простая математическая модель, описывающая реальное изображение с точностью, согласованной с точностью задания яркости изображения. Геометрическая форма белкового комплекса аппроксимируется эллипсоидом вращения. Параметры эллипсоида определяют классы, к которым принадлежат анализируемые комплексы.

Изменение формы поверхности белкового комплекса при напылении рассматривается как распространение фронта, скорость которого зависит от угла напыления и направления нормали в данной точке поверхности. Уравнение фронта запишем в виде

$$T(x_1, x_2, x_3) = t.$$

Скорость напыления в данной точке поверхности равна

$$u(x_1, x_2, x_3, \vec{n}) = I_0 \cos(\vec{n}, \vec{l})$$

Траектории движения фронта удовлетворяют каноническим уравнениям [2]

$$\frac{dx_i}{dt} = u^2 p_i, \quad \frac{dp_i}{dt} = -u \frac{\partial u}{\partial x_i} \|p\|^2, \quad p_i = \frac{\partial T(x_1, x_2, x_3)}{\partial x_i}, \quad i = 1, 2, 3$$

Пусть уравнения $S_0(x, y, z) = 0$ и $S(x, y, z) = 0$ определяют поверхность белкового комплекса до и после напыления соответственно. Тогда в каждой точке толщина металлической пленки будет равна

$$h(x, y) = z(x, y) - z_0(x, y)$$

Зависимость яркости в данной точке поля зрения от толщины пленки можно приближенно считать линейной до некоторого порогового значения толщины пленки, при котором происходит насыщение.

Морфологический анализ изображений белковых комплексов

Под изображением будет понимать некоторую функцию, заданную на подмножестве X плоскости R_2 .

Осуществим разбиение изображения на области постоянной яркости. Таким образом, отделим ту часть информации, которая ответственна за форму объекта (форма областей постоянной яркости) от несущественной с точки зрения свойств объекта части информации (непосредственной яркости данных областей). Тогда расчетное изображение можно представить в следующем виде

$$f(x) = \sum_{i=1}^N c_i \chi_i(x; a, b, \varphi, \theta, h), \quad x \in X \pmod{\mu}$$

Индикаторные функции областей постоянной яркости

$$\chi_i = \chi_i(a, b, \varphi, \theta, h) = \begin{cases} 1, & x \in A_i \\ 0, & x \notin A_i \end{cases}, A_i \cap A_j = 0, i \neq j, i, j = 1, 2, \dots, N$$

Количество областей постоянной яркости задается априори и равно четырем. При такой модели изображения объекта все его множество изображений можно представить в следующем виде

$$V_f = V_f(a, b) = \left\{ f(x) = \sum_{i=1}^N c_i \chi_i(x; a, b, \theta), c_i \in (-\infty, \infty), \theta \in [0, \pi] \right\}$$

Определенное таким образом множество назовем формой изображения объекта. При каждом фиксированном $\theta \in [0, \pi]$ форма изображения объекта является подпространством гильбертова пространства всех изображений $L_2^u(X)$. С каждым подпространством гильбертова пространства взаимнооднозначно связан оператор ортогонального проецирования. Построим явный вид оператора ортогонального проецирования на множество V_f

$$P_{V_f} g = \sum_{i=1}^N \frac{\int_{A_i} g(x) d\mu(x)}{\int_{A_i} d\mu(x)} \chi_i(x), x \in X(\text{mod } \mu),$$

где g - предъявленное изображение.

Определим наиболее близкий к g элемент V_f как решение задачи на минимум

$$\min_{\theta \in [0, \pi]} \|g - P_{V_f}(\theta)g\|^2$$

При изменении параметров a, b мы получим набор форм изображений в виде множеств $V_k = V_f(a_k, b_k)$. Задача состоит в выборе того класса изображений, к которому принадлежит предъявленное изображение g или к которому оно наиболее близко. Задача такой классификации сводится к задаче на минимум

$$\min_{k \in \{1, 2, \dots, n\}} \min_{\theta} \|g - P_k(\theta)g\|^2$$

Используя описанный алгоритм, можно определить, к какому классу

относится предъявленное изображение. Проведя эту процедуру для каждого комплекса на заданном изображении, можно установить, возможно ли осуществить разбиение на классы данных объектов.

Работа выполнена при поддержке РФФИ, грант № 05-01-00615-а.

Литература

1. Пытьев Ю.П. Методы морфологического анализа изображений. – В сб. Математические методы исследования Земли из Космоса. М.: Наука, 1984г.
2. Гельфанд И.М., Фомин С.В. Вариационное исчисление // ФИЗМАТЛИТ. Москва, 1961. С. 1-100.

Метод глубинной пассивной термографии тела человека

Д.Ю. Боснякова, М.С. Босняков, Ю.В. Гуляев, Ю.В. Обухов

(Москва)

В медицине существуют и развиваются диагностические методы и методы мониторинга процесса лечения, требующие измерения распределения температуры в глубине тела человека. Например, при дифференциальной диагностике рака используют углеводные (глюкозные) тесты, приводящие к разогреву раковых опухолей относительно здоровых тканей. А одним из эффективных методов лечения рака является гипертермия, при которой раковые образования разогреваются до $42 \pm 0,3^\circ\text{C}$. Несколько лет назад Комиссия по продуктам питания и лекарствам США (Food and Drug Administration FDA) и Комитет по новой технике Минздрава РФ рекомендовали не использовать для термографической диагностики и мониторинга инвазивные термодпары, поскольку они вызывают нежелательную реакцию организма и искажают реальное распределение внутренней температуры тела. В этой связи резко возрастает актуальность пассивных методов измерения и анализа поверхностной и глубинной температуры тела.

Существуют только два физических явления, позволяющие создать приборы для пассивной термографии – электромагнитное и акустическое излучения нагретого тела, распределенные по закону Планка. Согласно распределению Планка при температуре тела $\sim 300^\circ\text{K}$ мощность электромагнитного излучения имеет максимум в инфракрасном (ИК) диапазоне $\lambda \sim 10$ мкм, поэтому приборы инфракрасной термографии (тепловизоры) создавались в первую очередь и в течение последних двух десятилетий используются в различных разработках новых методов медицинской диагностики. Однако, из-за наличия скин-слоя, ограничивающего глубину проникновения (излучения) электромагнитного излучения в тело глубиной порядка длины волны, инфракрасная термография позволяет измерять распределение температуры на лишь поверхности тела. Конечно, вследствие температуропроводности

глубинная температура проецируется на поверхность тела, но восстановить глубинное распределение по поверхностным данным пока не удается.

Для пассивного измерения распределения температуры в глубине тела необходимо измерять длинноволновое (СВЧ) тепловое электромагнитное излучение. Интенсивность теплового СВЧ излучения, исходящего изнутри организма весьма мала - приблизительно 10^{-11} Вт с 1 см^2 в полосе частот 1 Гц. Но ее можно измерить современными методами с помощью радиометров. С помощью разработанного в ИРЭ РАН метода многоканальной глубинной радиотермографии в СВЧ диапазоне ($\lambda \sim 40 \text{ см}$) появилась возможность измерять распределение температуры в глубине тела. Были разработаны методы диагностики рака внутренних органов, эпилепсии, отклонений умственной деятельности в результате слабых поражений ионизирующим излучением.

Сущность метода регистрации теплового электромагнитного излучения заключается в том, что каждый элемент тела рассматривается как его источник, причем излучательная способность в соответствии с законом Кирхгофа прямо пропорциональна его поглощательной способности. Измеряется так называемая радиояркостная температура T_B . Она равна температуре абсолютно черного тела, которое создает такой же поток излучения, что и исследуемый объект и вычисляется по формуле:

$$T_B = (1 - R) \int_0^{\infty} T(x) \gamma(x) \exp\left(-\int_0^x \gamma(\xi) d\xi\right) dx \quad (1)$$

где интегрирование ведется от антенны (координата $x=0$) по нормали вглубь тела; множитель $\left(-\int_0^x \gamma(\xi) d\xi\right) dx$ описывает затухание

волны, распространяющейся к антенне с глубины x , $\gamma(\xi)$ – коэффициент затухания радиоволн в среде. Множитель $(1-R)$ возникает из-за влияния отражений на границе тело-антенна, описываемых коэффициентом отражения R . Глубина, с которой регистрируется радиотепловое излучение, зависит от структуры тканей под антеннами и температурного перепада в глубине, и составляет для мягких тканей $\sim 10 \text{ см}$ для головного мозга $\sim 2,5 \text{ см}$. Далее сигнал с периодом $1,8 \text{ с}$ передается в компьютер для последующей цифровой обработки. В компьютере производится сравнение этих сигналов с напряжением, соответствующим опорной температуре 35°C , полученная разность используется для дальнейшей обработки.

В качестве примера анализа радиотермограмм рассмотрим обследование группы больных – ликвидаторов ЧАЭС, получивших слабые дозы радиации, и контрольной группы здоровых людей. В качестве теста

использовался счет в уме. Для частотно-временного анализа сигналов радиотермографа в процессе счета в уме были построены вейвлет - преобразования с материнской функцией Морле для всех 12 каналов для каждого пациента. Была создана база данных частотно- временного представления сигналов радиотермографических обследований ликвидаторов ЧАЭС и здоровых людей. Оказалось, что вейвлет спектры сигналов имеют четко выраженную систему пиков в процессе счета. Выделив спектральные компоненты (зависимости от времени), соответствующие экстремумам этих пиков, нам удалось получить корреляционные матрицы межканальных связей, т.е. связей между участками мозга, которые отличают группу больных от группы здоровых людей.

Однако пространственное разрешение многоканального СВЧ радиометра составляет порядка 2 см, что недостаточно для ряда медицинских методик. Для создания приборов глубинной термографии с хорошим пространственным разрешением необходимо переходить к измерению теплового ультразвукового акустического излучения. В мегагерцовом диапазоне, в котором работают активные УЗИ приборы, длина волны составляет $\lambda \sim 1$ мм. Принцип акустической термографии заключается в измерении с помощью недорогих пьезодатчиков на поверхности тела давления теплового акустического ультразвукового излучения. Уравнение для давления на поверхности тела аналогично уравнению (1). Вследствие того, что глубина, с которой акустическое излучение доходит до поверхности, из-за поглощения ограничена и составляет ~ 10 см, создать томограф в обычной конфигурации с расположением датчиков вокруг всего тела невозможно. Поэтому были предложены и исследованы две конфигурации расположения датчиков на поверхности тела – на плоскости и на полуокружности.

Для томографа в плоской конфигурации разработаны методы и алгоритмы восстановления в том числе в равномерной норме с учетом априорной информации в виде уравнения теплопроводности с источником. Для полукруглой конфигурации томографа получено аналитическое решение обратной задачи акустической термотомографии. Данный подход основан на использовании экспоненциального преобразования Радона на полукруге.

Решением задачи акустотермотомографии при сканировании на полукруге является ряд Неймана для интегрального уравнения Фредгольма 2-го рода:

$$u = HKu - \frac{1}{2} H \int_{S_+^1} \frac{\partial R_\mu u}{\partial s}(\theta, x \cdot \theta) e^{-\mu x \theta^\perp} d\theta, \quad (2)$$

где u - искомое распределение температуры, $R_\mu u$ - экспоненциальное преобразование Радона искомого распределения температуры u , H - преобразование Гильберта, μ - коэффициент поглощения, s и θ - ось и угол проекции соответственно и K - интегральный оператор с непрерывным ядром:

$$K(x, y) = \frac{\cosh \mu(x - y) - 1}{x - y} \quad (3)$$

Работа поддержана Программой Президиума РАН «Фундаментальные науки-медицине», проектами РФФИ №№ 05-01-00651, 05-02-17646, 03-01-00723.

Методы и модели аутентификации/идентификации систем автоматического сканирования

С.П. Ботуз, С.С. Калыкин, И.М. Лисицын, В.С. Моисеева, С.Ю.

Четверов

(Москва)

На основе обзора патентов США, России, Германии, Японии и др. осуществлен критический анализ известных распределенных позиционных систем автоматического сканирования и соответствующих программных приложений, предназначенных для аутентификации/идентификации пользователей интегрированных оболочек CAD/CAE/CAM, использующие концепции utility computing – создание единого пула и динамическое перераспределение ресурсов между приложениями с поддержкой GRID-технологий. На базе проведенного анализа рассматриваются инструментальные методы для формирования персонафицированного графо-аналитического интерфейса и соответствующих вычислительных объектов, предоставляющих возможность повысить эффективность (безопасность, защищенность и т.п.) процессов аутентификации/идентификации субъектов и объектов интеллектуальной собственности CAD/CAE/CAM в сети Интернет/Интранет (или в вычислительной среде – ВС). 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 средств аутентификации/идентификации минимальной (ограниченной или, более точно, персонафицированной) сложности.

На основе использования известных интегрированных систем автоматизации проектирования (ИСАПР) радиоэлектронной аппаратуры (РЭА) и предлагаемого аппарата генерации персонифицированных графо-аналитических парадигм показана возможность в процессе сопровождения (аутентификации/идентификации) субъектов и объектов ИСАПР:

- осуществлять структурную и параметрическую декомпозицию задач позиционного (программного, ситуационного и др.) управления процессами автоматического сканирования объектов интеллектуальной собственности (ОИС) на основных этапах их жизненного цикла в сети Интернет/Интранет;

- выполнять в автоматизированном режиме формализацию содержания предметной области проектирования на основе генерации персонифицированных визуальных графо-аналитических отображений, взаимодействующих между собой по заданным субъектами правилам с поддержкой GRID-технологий;

- автоматически сравнивать по заданной графо-аналитической шкале показателей состояние наблюдаемого процесса взаимодействия между субъектами и объектами распределенных ИСАПР;

- проектировать персонифицированные подсистемы сопровождения субъектов и объектов промышленной собственности (ОПС: изобретений, полезных моделей, промышленных образцов) в открытом сетевом пространстве Интернет/Интранет;

- динамически перераспределять ресурсы между приложениями в зависимости от их функциональных потребностей, эффективно использовать программные механизмы UDC-wire once, reallocate many, например, выделять дополнительные ресурсы Web-системе ИСАПР из общего пула центра данных именно в те моменты времени, когда они ей будут необходимы, и передавать их другому приложению после того, как они освободятся.

В результате показано, что разработанные методики и модели экспертизы современных информационных технологий аутентификации/идентификации позволяют с большой степенью объективности оценить не только ту или иную спроектированную позиционную систему автоматического сканирования ИСАПР, но и синтезировать прогностические и оценочные характеристики ОПС и ОИС в заданной предметной области.

Литература

1. Bishop G., Fuchs H. Research Directions in Virtual Environmes / Computers and Graph-ics. 2003. Vol. 26. № 3. PP.153-177.
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. <http://hp.parallel.ru>
4. Ботуз С.П. Автоматизированный синтез нейроподобных структур и моделей идентификации нелинейных динамических процессов в Internet. – В кн.: Математические методы распознавания образов (МММО – 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. Методы проектирования и экспертизы технически оптимальных позиционных систем программного управления. Автореф. дис. докт. техн. наук. – М.: МИЭМ, 2003. – 30 с.

Реализация метода ускоренного выполнения кратковременного анализа

М.Б. Будько

(Санкт-Петербург)

В настоящее время актуальной является проблема повышения эффективности алгоритмов кодирования речевых сигналов для передачи последних по сетям связи. Автором предложен способ модернизации блоков спектрально-временного преобразования для ускоренного выполнения кратковременного анализа, и оценена вычислительная сложность предложенного подхода по сравнению с существующими методами.

Настоящая статья посвящена сравнению теоретических выводов и полученных результатов.

После анализа изменений отсчетов спектра были выведены общие формулы для получения каждого отсчета спектра на последующей итерации из значения соответствующего отсчета на предыдущей итерации для кратковременного дискретного преобразования Фурье (ДПФ) и кратковременного дискретного преобразования Хартли (ДПХ).

На рис.1 приведен график зависимости количества операций для выполнения преобразований от размеров окон N для наглядного сравнения вычислительных сложностей существующих быстрых алгоритмов и предложенных (оптимизированных).

Таким образом, теоретически рациональнее выполнить:

– либо замену алгоритмов на основе ДПФ на алгоритмы, осуществляющие преобразование Хартли (ПХ) предложенным способом для получения результата ПХ, первое «окно» рассчитывается с помощью быстрого преобразования Хартли (БПХ);

– либо рассчитывать первое «окно» с помощью БПХ с последующим перерасчетом в результат Фурье-преобразования (ПФ), а последующие – предложенным способом для получения ПФ.




Рис.1

На рис.2 представлены полученные в результате выполнения программы графики зависимостей времен выполнения преобразований от размеров окон. Графики следует воспринимать с точки зрения относительных значений, а не абсолютных.




Рис.2

Как видно, экспериментальные зависимости имеют такую же тенденцию к возрастанию, как и теоретические. Однако скорость изменения графиков, соответствующих БПФ и БПХ несколько выше, что

объясняется достаточно большим количеством циклов `for ... end` в функциях, реализующих соответствующие преобразования, использованием временных переменных, затратами на вызов самих функций и т.п.

Достоинства предложенного метода: высокая скорость вычислений и линейная зависимость скорости вычислений от размера «окна».

Недостаток предложенного метода: наличие погрешности вычислений.

В виду ограниченности форматов представления данных в ЭВМ результаты вычислений в подавляющем большинстве случаев представляют собой округленные значения. Поскольку даже при обычном вычислении ПФ или ПХ имеет место быть ошибка, то при последующих расчетах на основе округленных значений погрешность будет возрастать.

Для оптимизированных ПФ и ПХ были рассчитаны относительные погрешности как отношение суммы модулей разностей значений, полученных при использовании оптимизированного и быстрого алгоритмов, к сумме значений, полученных при использовании быстрого алгоритма. В качестве обработки деления на ноль использовалась подстановка предыдущего вычисленного значения погрешности.

При выполнении оптимизированного ПФ значения погрешности очень малы (после более 10 000 окон относительная погрешность порядка 10^{-10} %), хотя, очевидно, что когда-нибудь возникнет необходимость пересчитать спектр по стандартному алгоритму или равноценному ему. Но т.к. количество рассчитанных «окон» по оптимизированному методу велико, то на среднем значении вычисления одного «окна» это практически не отразится.

С предложенным методом ПХ дело обстоит хуже: относительная погрешность при 1-ом вычислении – 2.2473×10^{-10} %, 2-ом – 41.1354 %, 3-ем – 69.0293 % и т.д.

Поэтому в программе используется подход с чередованием: вычисление БПХ, вычисление оптимизированного ПХ. При этом время вычисления увеличивается с $t_{\text{оптимиз.ПХ}}$ до значения:

$$\frac{(t_{\text{БПХ}} + t_{\text{оптимиз.ПХ}})}{2} \approx \frac{t_{\text{БПХ}}}{2},$$
 что также является значительным

сокращением времени преобразования.

Для устранения недостатка предложенного метода необходимо:

- применение расширенных форматов представления данных;
- при достижении критического значения погрешности пересчет спектра по стандартному алгоритму.

Полученные практические результаты подтвердили эффективность предложенных методов преобразования. Можно сделать следующий

Вывод:

– для сокращения времени выполнения кратковременного анализа следует первое «окно» вычислять с помощью БПХ с последующим преобразованием вычисленных значений в результат ПФ, а последующие «окна» на основе предложенного метода для ПФ;

– вторым по эффективности является расчет первого «окна» на основе БПХ, а последующих – предложенным методом для ПФ с чередованием.

Следует отметить, что выводы совпадают с теоретическими, несмотря на неизбежные отклонения, вносимые спецификой программной реализации.

Литература

1. Брейсуэлл Р., Преобразование Хартли: Пер. с англ. // Мир. М., 1990. С. 76-120.

Определение значимости тематических запросов к информационно-поисковой системе на основе модели графа связей запросов

А.В. Васильев

(г. Барнаул)

Введение

Интернет – это один из наиболее важных и значительных по объему источников информации. На сегодняшний день проблему поиска в Интернете наиболее успешно решают информационно-поисковые системы (ИПС). Электронный архив ИПС – это своеобразное отражение Интернета. Извлечение знаний из электронных архивов ИПС – одна из самых актуальных задач научного направления в обработке информации, получившего название Data Mining. Задачи Data Mining состоят в выявлении скрытых правил, закономерностей, знаний в больших массивах, базах данных разнородной информации. В этом случае применяются нейросетевые алгоритмы, методы распознавания образов, теории графов, методы математической статистики и т.д. [1]. Данная работа посвящена решению одной из задач извлечения знаний из архивов ИПС – определению значимости тематических запросов к ИПС.

В качестве простой оценки значимости тематического запроса можно использовать количество документов, выдаваемых на запрос. Данная оценка не учитывает связи между запросами заданной тематической области. В работе предлагается другой подход к оценке значимости тематического запроса, основанный на модели графа связей запросов.

Математическая модель и алгоритмы

Пусть дано множество запросов $Q = \{q_1, q_2, \dots, q_n\}$, описывающих

некоторую тематическую область информационного поиска. На запрос q_i ИПС возвращает множество документов D_i , содержащих данный запрос. Кроме запроса q_i множество D_i может содержать и другие запросы из множества Q . Обозначим через p_{ij} частоту вхождения запроса q_j во множество D_i . Частота определяется как отношение $p_{ij} = n_{ij} / N$, количества запросов q_j во множестве D_i к общему количеству запросов из множества Q во множестве D_i . Таким образом, по определению $0 \leq p_{ij} \leq 1$.

Построим ориентированный взвешенный граф G с вершинами $Q = \{q_1, q_2, \dots, q_n\}$. Частоты p_{ij} будем рассматривать как веса дуг (q_i, q_j) . Данный граф отражает связи между запросами. Наша цель заключается в разработке алгоритмов определения степени значимости вершин графа G .

Алгоритмы расчета значимости вершин графа G будем строить на основе хорошо известных алгоритмов ранжирования вершин графа Веб – PageRank и HITS [2,3].

Модифицированный алгоритм PageRank для задачи определения значимости запросов принимает форму

$$r_i(k+1) = \alpha \cdot \sum_{j=1}^n p_{ji} r_j(k) + \frac{1-\alpha}{n},$$

где $0 < \alpha < 1$ – параметр алгоритма, $r_i(k)$ – значимость запроса q_i , определяемая рекурсивно.

Алгоритм HITS также применяется для определения рангов страниц Веба. В отличие от PageRank алгоритм HITS для каждой страницы вычисляет два ранга, которые называются рангами «лидера» и «посредника» («authority» и «hub»). Модифицированный HITS для задачи определения значимости запросов описывается уравнениями:

$$r_i(k+1) = \sum_j p_{ij} w_j(k), \quad w_i(k+1) = \sum_j p_{ij} r_j(k).$$

На каждом шаге также выполняется нормирование векторов $r(k+1)$ и

$w(k+1)$. Рекуррентно вычисляя ранг «лидера», получим итоговую значимость запросов.

Результаты экспериментов

Проведем сравнение полученных результатов для простой оценки значимости запросов, для алгоритмов PageRank и HITS. В рассматриваемом эксперименте в качестве тематической области была взята область науки Control Engineering. Данная область поиска была описана следующим набором запросов: $q_1='optimal' \& 'control'$; $q_2='adaptive' \& 'control'$; $q_3='robust' \& 'control'$; $q_4='linear' \& 'control'$; $q_5='nonlinear' \& 'control'$; $q_6='identification' \& 'control'$; $q_7='predictive' \& 'control'$; $q_8='hybrid\ system' \& 'control'$; $q_9='fuzzy' \& 'control'$; $q_{10}='discrete\ event' \& 'control'$.

Запросы направлялись поисковой системе Google. Поиск осуществлялся среди PDF-документов. Множества D_i составлялись из первых десяти документов результатов поиска. В итоге была построена матрица смежности P для графа связей G .

Дальнейшие вычисления выполнялись согласно приведенным выше формулам с параметром $\alpha = 0,8$ и начальным значением $r(0) = e/n$.

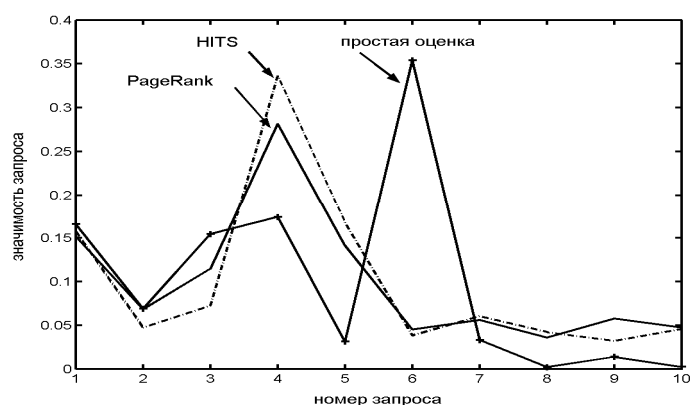


Рис. 1 Значимость тематических запросов для простой оценки, PageRank и HITS.

Для простой оценки самым значимым оказался запрос q_6 со значением 0.35409, для PageRank и HITS — q_4 со значениями 0.28186 и 0.33618 соответственно. Наглядно результаты можно сравнить на рисунке 1. Из рисунка видно, что модификации PageRank и HITS имеют одну тенденцию и отличаются незначительно.

Заключение

Описанные в данной работе модификации алгоритмов PageRank и HITS могут быть применены для решения задачи определения значимости тематических запросов к поисковой системе или иной базе данных текстовых документов. Указанные алгоритмы учитывают информацию о связи запросов между собой. Проведенные численные эксперименты подтверждают работоспособность данных алгоритмов и их преимущество по сравнению с простой оценкой значимости.

Литература

1. Дюк.В.Самойленко А. Data Mining Учебный курс. СПб.: – Питер , 2001 – 368с.
2. Brin S., Page L. The anatomy of a large-scale hypertextual web search engine// Proceedings of the 7th International World Wide Web Conference. (Brisbane, Australia, 1998. (pp. 107-117.
3. Kleinberg J.M. Authoritative sources in a hyperlinked environment// Journal of ACM. – 1999. – Vol. 46. – N5 – pp. 604-632

Распознавание линейных объектов с периодической формой представления

Ю.Г. Васин, Л.И. Лебедев

(Нижний Новгород)

Введение

Автоматизация ввода сложных графических документов предполагает использование алгоритмов автоматического распознавания различных дискретных, линейных и площадных объектов. В первую очередь автоматическое распознавание применяется для наиболее часто встречающихся объектов, а также объектов, ввод которых в интерактивном режиме является многокритериальной процедурой и поэтому является проблемной задачей. К таковым относится ввод линейных объектов топографических и морских карт и планов. Для линейных объектов из-за их габаритов в противоречие вступают получаемая точность отображения объекта на экране, связанная с размерами выбранного окна, необходимая точность формирования метрического описания объекта и трудоемкость процедуры интерактивного ввода таких объектов. В данной работе предлагается алгоритм распознавания элементов содержания документа, интерпретируемых как линейные объекты, которые графически изображаются посредством периодических функций.

Постановка задачи

Рассматриваемый тип линейных объектов на плоскости XOY можно представить последовательностью узловых точек, каждая пара которых

определяет направление, интерпретируемое как ось абсцисс для некоторой периодической функции. Распознавание заключается в определении местоположения узловых точек и вида функции, используемых в анализируемом линейном объекте.

Методы решения

Для решения задачи распознавания рассматриваемого типа линейных объектов был применен корреляционно-экстремальный метод [1]. В качестве эталонной информации для этого метода использовался один период каждой из функций, вид которых требовалось определить. Таким образом, задача распознавания линейных объектов с периодической формой представления в определенной степени аналогична решению задачи навигации роботов [2]. Поэтому, результаты, полученные при решении задачи навигации роботов, могут быть использованы и для решения нашей задачи.

Полученные результаты

Для определения вида используемой периодической функции вначале на базе линейно-контурной модели представления информации необходимо получить метрическое описание обрабатываемого объекта [3]. Затем в соответствии с длиной (периодом) текущего эталона сформировать текущий фрагмент кривой и, используя корреляционно-экстремальный метод, вычислить коэффициент сходства. Далее двигаясь вдоль кривой, представляющей рассматриваемый линейный объект, с заданным шагом на протяжении одного периода можно определить фрагмент с максимальным коэффициентом сходства. Осуществляя эту процедуру для всех заданных эталонных последовательностей, выбирается тот вид задания периодической функции, для которой был получен наибольший коэффициент сходства, если, конечно, он превосходит наперед заданную величину.

Основные трудности в предлагаемом алгоритме распознавания линейных объектов с периодической формой представления заключаются в определении с заданной точностью местоположения узловых точек, соответствующих точкам излома осевой линии рассматриваемой кривой. Для того, чтобы определить положение узловой точки, необходимо распознать фрагмент кривой длиной в период, сформированный непосредственно до или после точки излома. Описание этого фрагмента от эталонного может отличаться только циклическим сдвигом последовательности точек (фазой, в амплитудно-фазовом представлении данных о рассматриваемом линейном объекте), однако для корреляционно-экстремального метода эти описания задают две разные формы кривых. Для успешного распознавания всех возможных фрагментов, образованных циклическими сдвигами точек базового описания эталона, можно предложить несколько вариантов решения

задачи.

1. Для распознавания данного вида периодической функции можно использовать не один эталон, а группу эталонов, сформированных на основе циклического сдвига базового. Количество и состав полученных таким образом эталонов полностью определяются точностью нахождения местоположения узловых точек и минимальным значением коэффициента сходства.

2. Находится базисная система функций, на основе которой каждый фрагмент кривой можно было бы представить с заданной точностью. В частности, эту систему можно получить ортогонализацией сформированных вышеописанным способом группы эталонов. Этот вариант является менее наглядным, чем предыдущий, однако позволяет получить одинаковые результаты при меньшем количестве эталонов в группе. Так для синусоидальных сигналов здесь достаточно двух эталонов, один из которых получается на основе первого циклическим сдвигом на четверть периода.

3. Для каждого вида периодической функции задается только один эталон, соответствующий двум периодам. Тогда любой фрагмент рассматриваемой периодической функции будет представлен в эталонном описании. Задача состоит в нахождении участка на эталоне наиболее сходного с выделенным фрагментом и определения местоположения этого участка. Эта задача аналогична задаче нахождения согласованных описаний и может быть решена теми же методами [4].

Распознавание вида функции, используемой в анализируемом линейном объекте и определение местоположения узловых точек (осевой линии рассматриваемого объекта) было исполнено на базе алгоритма, реализующего третий вариант решения задачи. Выбор этого варианта обусловлен несколькими причинами. Во-первых, используется меньшее количество эталонов (очевидно, что для задания эталонной информации здесь достаточно и одного периода на каждый вид функции), во-вторых, используется оптимизированная процедура поиска согласованных описаний. Это в совокупности обеспечивает оптимальное быстроедействие алгоритма распознавания. Кроме того, реализация этого варианта решения задачи позволяет в автоматическом режиме увеличивать состав распознаваемых периодических функций. Очевидно, что для этого достаточно только задать в качестве эталонного описание одного периода новой периодической функции.

Выводы

Предлагаемый алгоритм распознавания линейных объектов с периодической формой представления применялся при создании цифровых моделей морских карт. Полученные оценки быстродействия алгоритма и качества формируемой осевой линии объекта подтвердили его

высокую эффективность.

Работа выполнена при поддержке РФФИ (проект № 05-01-00590).

Литература

1. Васин Ю.Г., Васин Ю.Г., Лебедев Л.И., Пучкова О.В. Контурные корреляционно-экстремальные методы обнаружения и совмещения объектов видеоинформации./Автоматизация обработки сложной графической информации: Межвуз.темат.сб.науч.тр./Под ред. Ю.Г.Васина.- Горьков. гос. ун-т, Горький, 1987. С.97-112.
2. Васин Ю.Г., Лебедев Л.И., Пучкова О.В. Корреляционно-экстремальный метод в задачах навигации роботов и ввода дискретных объектов.//Методы и средства обработки сложной графической информации: 3-я Всесоюз. конф.: Тез.докл./Горький, Горьков.гос. ун-т, 1988, ч.1. С.61-62.
3. Автоматизация обработки сложной графической информации: Межвуз. сб. науч. труд. / Под ред. Ю.Г. Васина. - Горький, Горьков. гос. ун-т, 1985. - 195с. : 1987. - 166 с. : 1988. - 124 с.
4. Васин Ю.Г., Лебедев Л.И., Методы определения сходства плоских форм и алгоритмы определения согласованных описаний.//Методы и средства обработки сложной графической информации: 4-я Всесоюз.конф.: Тез.докл./ Нижний Новгород, Нижегород.гос. ун-т, 1991, ч.1. С.109-110.

Обучение распознаванию образов в анализе данных опросов населения

Е.Б. Галицкий, В.В. Моттль, А.И. Татарчук
(Москва)

Введение

Для самых разных общественных институтов представляют огромный интерес структура населения по состоянию здоровья, экономическому положению, предпринимательской деятельности, предпочтениям к разным группам товаров, отношению к политическим партиям и движениям, отдельным политическим лидерам, и т.п. [1]. Обычно объектом интереса подобного рода является население определенной страны либо некоторая часть населения, например, совершеннолетние граждане, но в любом случае исследованию подлежит некоторая конечная популяция $\omega \in \Omega$, $|\Omega| < \infty$, где $|\Omega|$ – число элементов в популяции.

Пусть интересующие исследователя свойства элементов популяции могут быть измерены формальными переменными $x_i(\omega)$ в соответствующих шкалах $x_i(\omega) \in X_i$, $i = 1, \dots, k$. Вся популяция в целом $\omega \in \Omega$ образует некоторое распределение точек $\mathbf{x}(\omega) = [x_1(\omega), \dots, x_k(\omega)]$ в пространстве свойств $\mathbb{X} = X_1 \times \dots \times X_k$, причем изучение этого

распределения является конечной целью всякого исследования популяции. Изучение распределения элементов популяции в пространстве их свойств заключается в выявлении «типичных» и «вероятных» сочетаний значений свойств в противовес «редким», и даже «невозможным» сочетаниям. Исследования, как правило, проводятся путем анализа результатов опросов в относительно небольших выборках, формируемых по тем или иным принципам, обычно, путем случайного отбора респондентов [2].

Приближенные зависимости между свойствами элементов популяции

Целью настоящего доклада является исследование специфики оценивания зависимости одних свойств, измеряемых в дискретных шкалах, от других свойств элементов популяции по конечной выборке $\Omega^* = \{x(\omega_j) = [x_1(\omega_j), \dots, x_k(\omega_j)], j = 1, \dots, N\} \subset \Omega$ (обучающей совокупности), построенной по принципу случайного равновероятного выбора $q(\omega) = 1/|\Omega|$ с возвращением как способа помочь исследователю составить наглядное представление, по крайней мере, об основных чертах полного распределения вероятностей.

Пусть i – индекс некоторого свойства элементов популяции (целевого свойства), для которого требуется найти приближенную оценку значения

$$\hat{x}_i(\omega) = f(x_l(\omega), l \neq i) \cong x_i(\omega) \quad (1)$$

в своей шкале $\hat{x}_i(\omega) \in X_i$ от значений других свойств (аргументов) $x_l(\omega) \in X_l, l \neq i$, в классе достаточно простых функций $f(x_l(\omega), l \neq i)$. Естественно, что прежде чем приступить к решению такой задачи, необходимо определить, как следует количественно измерять несовпадение истинного и оцененного значения целевого свойства (1), а также что понимать под «простыми» функциями $\hat{x}_i(x_l(\omega), l \neq i)$.

Специфика анализа данных опросов населения заключается в том, что интересующие исследователя свойства элементов популяции определяются специальной формулировкой вопросов в анкете, предлагаемой респондентам. В данном докладе мы используем метод потенциальных функций, согласованный с принятой структурой вопросов. С каждым вопросом анкеты (исследуемым свойством элемента популяции) мы связываем одну специально построенную потенциальную функцию, погружающую множество респондентов в специфическое линейное пространство со скалярным произведением, в котором несовпадение значений переменных определяется соответствующей евклидовой метрикой. Совокупность вопросов анкеты порождает конечное множество линейных пространств, декартово произведение которых, в свою очередь, образует некоторое результирующее линейное пространство, в которое погружается исследуемая популяция и в котором роль «простых» функций играют линейные функции.

Потенциальные функции, связанные с вопросами анкеты

Рассмотрим пример вопроса, типичного для опросов населения:

Есть ли в Вашей семье дети в возрасте от 13 до 20 лет? Если есть, то Ваша семья готова или не готова пойти на серьезные материальные затраты ради того, чтобы они получили высшее образование?

Ответ на этот вопрос заключается в выборе одного из шести вариантов:

- (1) детей в возрасте от 13 до 20 лет нет; (2) безусловно готовы; (3) скорее готовы; (4) скорее не готовы; (5) безусловно не готовы; (6) затрудняюсь ответить.

Пусть i – индекс вопроса, тогда шкала для измерения соответствующего свойства есть конечное множество $x_i(\omega) \in X_i = \{1, \dots, m_i\}$. В данном случае эту шкалу нельзя целиком отнести ни к номинальному, ни к ранговому типу, поскольку группы $\{1, \{2, 3, 4, 5\}, 6\}$ относятся друг к другу как элементы номинальной шкалы, а фрагмент $\{2, 3, 4, 5\}$ представляет собой встроенную ранговую шкалу.

Основная идея подхода к организации анализа данных опросов населения, рассматриваемого в данном докладе, заключается в погружении шкалы измерения каждого свойства $x_i(\omega)$ в линейное пространство [3]. По каждому вопросу анкеты с социологом согласовывается метрика на множестве вариантов ответа $\rho_i(x_i', x_i'')$, $x_i', x_i'' \in X_i$, количественно выражающая представление социолога о различии элементов популяции $\rho_i(\omega', \omega'') = \rho_i[x_i(\omega'), x_i(\omega'')]$ с точки зрения данного вопроса. Определяется симметрическая двухместная функция

$$K_i(\omega', \omega'') = (1/2) \{ \rho_i^2[x_i(\omega'), \phi_i] + \rho_i^2[x_i(\omega''), \phi_i] - \rho_i^2[x_i(\omega'), x_i(\omega'')] \},$$

где $\phi_i \in X_i^{(i)}$ – один из элементов шкалы, выбранный в качестве центра. В случае конечной шкалы $x_i(\omega) \in X_i = \{1, \dots, m_i\}$ все возможные значения функции $K_i(\omega', \omega'')$ исчерпываются симметрической матрицей $(m_i \times m_i)$. Можно показать [3], что если эта матрица положительно определена, то метрика $\rho_i(\omega', \omega'')$ погружает популяцию в некоторое линейное пространство, в котором функция $K_i(\omega', \omega'')$, называемая потенциальной функцией (kernel function в англоязычной терминологии), играет роль скалярного произведения элементов. Следует заметить, что факт положительной определенности матрицы возможных значений функции $K_i(\omega', \omega'')$ на зависит от выбора центра $\phi_i \in X_i$ [3], более того, роль центра может играть гипотетический элемент линейного пространства, в которое погружается конечное множество X_i , тогда $\phi_i \notin X_i$.

Оценивание зависимости бинарного свойства от значений других свойств

Ограничимся рассмотрением целевых переменных (1) бинарного типа $x(\omega) = x_i(\omega) \in X_i = \{-1, 1\}$, приняв обозначение $n = k - 1$ для числа свойств-

аргументов, дополнительных по отношению к целевому свойству $l \neq i$. Бинарная переменная может быть образована из любой переменной с дискретной шкалой путем произвольной классификации множества ее значений на два класса. В этом случае восстановление зависимости (1) эквивалентно обучению распознаванию образов с двумя классами по вектору признаков $x_l(\omega)$, $l=1, \dots, n$, а во втором – оцениванию регрессионной зависимости по этим переменным, играющим роль регрессов, вообще говоря, нечисловых.

Пусть $\Omega^* = \{x(\omega_j), x_1(\omega_j), \dots, x_n(\omega_j), j = 1, \dots, N\} \subset \Omega$ – конечная выборка элементов популяции (обучающая совокупность). Свяжем с целевым свойством действительную переменную $y(\omega)$ и линейную функцию $y(\omega) = \sum_{i=1}^n \sum_{j=1}^N a_{ij} K_i(\omega_j, \omega) + b$, где a_{ij} и b – действительные параметры. Примем в качестве целевой характеристики знак этой линейной функции, тогда выбор параметров задает некоторую классификацию объектов на два класса: $y(\omega) > 0 \rightarrow$ класс 1, $y(\omega) \leq 0 \rightarrow$ класс -1. Для оценивания значений параметров a_{ij} и b мы используем критерий,

$$\begin{cases} \sum_{i=1}^n \left[(1/r_i) \sum_{j=1}^N \sum_{l=1}^n a_{il} a_{ij} K_i(\omega_j, \omega_l) + \log r_i \right] + C \sum_{j=1}^N \delta_j \rightarrow \min(a_{ij}, r_i), \\ x(\omega_j) \left[\sum_{i=1}^n \sum_{l=1}^n a_{il} K_i(\omega_j, \omega_l) + b \right] \geq 1 - \delta_j, \delta_j \geq 0, j = 1, \dots, N, \end{cases}$$

предложенный в работе [4] и являющийся существенным обобщением известного критерия опорных векторов В.Н. Вапника [5]. Алгоритм минимизации этого критерия рассмотрен в [4], и приводит к решающему правилу вида

$$y(\omega) = \sum_{j=1}^N \lambda_j x(\omega_j) \sum_{i=1}^n r_i K_i(\omega, \omega_j) + b,$$

где $(\lambda_j \geq 0, j = 1, \dots, N)$ и $(r_i \geq 0, i = 1, \dots, n)$ – неотрицательные величины, большинство из которых, как правило, оказываются равными нулю.

В данном докладе для нас особенно важно то обстоятельство, что величины r_i , существенно отличающиеся от нуля, непосредственно указывают на те вопросы анкеты, ответы на которые практически полностью определяют значение целевого свойства элементов популяции.

Литература

1. Rossi P.H., Wright J.D., Anderson A.B., Eds. Handbook of Survey Research (Quantitative Studies in Social Relations). Academic Press, San Diego, 1983.
2. Särndal C.-E., Swensson B., Wretman J. Model Assisted Survey Sampling. Springer Verlag, 2003, 694 p.
3. Моттль В.В. Метрические пространства, допускающие введение

- линейных операций и скалярного произведения. ДАН, 2003, том 388, № 3, с. 1-4.
4. Моттль В.В., Середин О.С., Красоткина О.В., Мучник И.Б. Комбинирование потенциальных функций в задачах восстановления зависимостей по эмпирическим данным. ДАН, 2005, том 401, № 5, с. 607-612.
 5. Vapnik V. Statistical Learning Theory. John-Wiley & Sons, Inc. 1998.

Предварительная фильтрация при иерархической компрессии изображений

М.В. Гашиков, Н.И. Глумов
(Самара)

Иерархическая компрессия изображений

Иерархическая компрессия изображений [1,2] основана на использовании прореженных копий изображения для интерполяции промежуточных отсчетов и последующем энтропийном кодировании ошибок интерполяции (постинтерполяционных остатков). В данной работе в качестве иерархического метода сжатия рассматривается метод иерархической сеточной интерполяции (ИСИ) [1]. Метод обладает чрезвычайно низкой вычислительной сложностью, высоким коэффициентом сжатия, позволяет контролировать погрешность и обладает многими другими достоинствами, характерными для иерархических методов сжатия.

Одним из недостатков метода ИСИ является снижение визуального качества декомпрессированных изображений при больших коэффициентах сжатия, обусловленное использованием равномерной шкалы квантования для постинтерполяционных остатков. Снижение качества происходит из-за того, что любая точка восстановленного изображения может изменить свою яркость на величину интервала квантования шкалы, а на «гладких» участках (участках с плавно меняющейся яркостью) это приводит к появлению «выбитых» пикселей и небольших пятен (размером в несколько пикселей), яркость которых заметно отличается от яркости окружающих пикселей.

Такой эффект происходит в тех точках, в которых интерполяция производится неточно. В свою очередь интерполяция на гладких участках будет неточна вокруг пикселей, яркость которых сильно отличается от окружающих, то есть, прежде всего, на шумовых пикселях.

В данной работе предлагается способ уменьшения этого эффекта за счет предварительной фильтрации изображения.

Предварительная фильтрация

Предварительная фильтрация в задаче компрессии производится до

собственно сжатия изображения. Такая фильтрация, естественно, вносит погрешность, но, при правильном выборе фильтра, фильтрованное изображение может стать более «удобным» для данного метода сжатия, за счет чего схема обработки с предфильтром в результате может оказаться более эффективной.

Исходя из вида погрешности метода ИСИ, отмеченного выше, предфильтр должен подавлять малые шумы на участках плавно меняющейся яркости, при этом, по возможности оставляя нетронутой полезную информацию изображения, в частности контурные линии. Такими свойствами обладает сигма-фильтр [2], представляющий собой усреднение по тем пикселям заданного окна обработки, значение яркости которых отличается от яркости центрального пикселя окна не более чем на заданную величину σ , которая является параметром фильтра.

Вычислительный эксперимент

Для исследования эффективности схемы с предварительной фильтрацией она сравнивалась с «чистым» методом ИСИ в координатах PSNR-коэффициент сжатия [2]. Типичные результаты показаны на рис. 1, откуда видно, что схема с предфильтрацией имеет выигрыш.

На рис. 2 показаны фрагменты восстановленных изображений для схем без предфильтра и с предфильтром соответственно. Изображения имеют приблизительно одинаковую погрешность, но при этом изображение для схемы с предфильтром лучше по визуальному качеству и ему соответствует больший коэффициент компрессии.




Рис. 1. Зависимость PSNR от коэффициента сжатия для стандартного метода ИСИ и метода ИСИ с предфильтрацией

Полученные результаты позволяют сделать вывод о том, что использование сигма-предфильтрации является перспективным при

иерархической компрессии изображений.

Благодарности

Работа выполнена при поддержке:

- Министерства науки и 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);
- Российского фонда фундаментальных исследований (РФФИ), грант 04-01-96507.



Рис. 2. Фрагменты декомпрессированных изображений (погрешность одинакова):
(а) стандартный метод ИСИ; (б) метод ИСИ с префильтром.

Литература

1. Гашников М. В., Глумов Н. И., Сергеев В. В. Метод компрессии

- изображений в системах оперативного дистанционного зондирования // Доклады IX Всероссийской конференции “Математические методы распознавания образов” (ММРО-9-99) С.160-163.
2. Методы компьютерной обработки изображений // Под редакцией В.А.Сойфера. - М.: Физматлит, 2001. - 784 с.

**Отдельные алгоритмы, применяемые в реализации
морфологического метода сравнения радужных оболочек
глаз**

Н.И. Голов
(Москва)

Введение

Данная работа посвящен одному из методов решения задачи биометрической идентификации/верификации человека. В качестве источника данных для верификации/идентификации используется радужная оболочка человеческого глаза. Упомянутый в названии морфологический метод является альтернативой хорошо известному методу J.G. Daugman [1], основанному на сравнении вейвлетных описаний текстурных особенностей радужных оболочек глаз. Главным отличием морфологического метода является использование не всех текстурных данных радужной оболочки, а только данных о морфологической структуре волокнистой структуры радужной оболочки, так называемой стромы.

Работа выполнена при поддержке РФФИ, грант 05-01-00542, под руководством профессора Местецкого Л. М.




Рис. 1. Радужная оболочка только с рисунком стромы (справа), и с дополнительной пигментацией (слева).

На рис. 1. можно видеть пример стромы на двух различных радужных оболочках. При этом на левой оболочке кроме рисунка стромы присутствуют еще и пигментные пятна, которые регистрируются алгоритмом [1] наравне со стромой, но могут меняться со временем. В

данном докладе будут описаны алгоритмы, разработанные для выделения структуры стромы на изображении.

Строма образована множеством не прямых линий различной толщины, пересекающихся и накладывающихся друг на друга. Поэтому традиционные способы прослеживания линий оказались неэффективными для ее выделения. Был разработан алгоритм, основанный на локальном прослеживании направления линий, и построении общей карты линий путем рекурсивного применения локального прослеживания. Первым этапом, необходимым для эффективного (по быстродействию) применения локального прослеживания, является этап поиска стартовых точек.

Стартовыми точками называются точки изображения, удовлетворяющие двум требованиям: каждая точка должна располагаться строго в центре (по ширине) некоторой линии, и общая плотность таких точек на изображении должна быть невелика (требование быстродействия). Первое требование необходимо, так как из каждой стартовой точки предполагается запускать алгоритм локального прослеживания, и при нарушении первого требования его работа становится непредсказуемой. Для поиска стартовых точек на изображении задается мера, определяющая степень принадлежности каждой точки некоторой линии. Чем четче и выраженнее линия, к которой принадлежит точка, тем выше мера. Мера вычисляется функцией на изображении. В дальнейшем эту меру будут называть G-яркостью. На рис. 2 можно видеть исходный фрагмент радужки (слева), и построенную по нему карту G-яркости (центр). Затем для поиска стартовых точек все изображение делится на прямоугольные участки, количество которых определяется требуемой плотностью стартовых точек. В каждом участке ищется точка с максимальной G-яркостью, а затем по суммарной G-яркости области проверяется гипотеза о том, что эта точка принадлежит линии (что некоторая линия действительно проходит через область). Если гипотеза принимается, точка помечается как стартовая. На рис. 2 (справа) обозначены найденные алгоритмом стартовые точки.



Рис. 2. Фрагмент радужки, карта G-яркости и найденные стартовые точки

Алгоритм локального прослеживания линий использует такие локальные свойства линий изображения, как значительное превышение

производной в направлении, перпендикулярном направлению линии, над производной вдоль линии, как превышения яркости линии над яркостью фона и определенная устойчивость линии по направлению. Линия прослеживается как упорядоченная последовательность точек, так называемая трасса. Описанные ранее локальные свойства линии были формализованы как функция, вычисляемая по трассе. Таким образом, локальное прослеживание основано на выборе в некоторой окрестности используемой стартовой точки такой трассы, которая начинается в стартовой точке, доходит до границ окрестности и оптимизирует значение функции. Поиск производится с использованием методов динамического программирования.




Рис. 3. Этапы локального прослеживания наилучшего направления линии.




Рис. 4. Фрагмент радужки с найденными локальными фрагментами линий.

После нахождения наилучшего положения трассы в локальной окрестности стартовой точки алгоритм локального прослеживания рекурсивно запускается из последней точки трассы, пытаясь сохранить общее направление трассы и добавить к ней новый фрагмент (см. рис 4, справа). После каждой попытки наращивания трасса верифицируется по суммарной G-яркости всех ее точек. Если верификация не проходит, то наращивание отменяется, трасса признается построенной и запоминается.

Найденный описанным алгоритмом набор трасс был использован в качестве инвариантного описания радужного оболочки и применялся для сравнения различных радужных оболочек. В результате проведения 2048 экспериментов по сравнению на основе построенных на радужке трасс была достигнута 100% точность верификации.

Литература

1. Daugman J.G., Demodulation by Complex-Values Wavelets for Stochastic Pattern
2. Li Ma, Tieniu Tan, Yunhong Van, Dexin Zhang, Personal Identification Based on Iris Texture Analysis
3. Девид Форсайт, Жан Понс, Компьютерное зрение, современный подход
4. Голов Н. И., Белаковский Д. И., Метод определения межплоскостных расстояний кристаллов по рентгенограммам

Моделирование случайных мозаик для задач обработки данных лесной таксации

П.Я. Грабарник, В.Э. Смирнов

(Пушино)

Инвентаризация (таксация) лесного фонда осуществляется на основе рационального сочетания наземных и дистанционных методов. Целью лесной таксации является описание лесных участков: породный состав древостоев, возраст, средняя высота и средний диаметр деревьев, товарность и ряд других характеристик, а также составление лесоустроительных карт. Снимки аэрокосмической фотосъемки служат вспомогательным материалом в зоне интенсивного природопользования и часто единственным способом учета лесного фонда, не вовлеченного в эксплуатационную деятельность. Дешифрирование материалов аэрокосмической фотосъемки является задачей распознавания образов, состоящей в классификации элементов (пикселей) изображения. Выделение однородных лесных участков при составлении лесоустроительных карт соответствует задаче сегментации изображения.

Одним из подходов в задачах обработки изображений является использование марковских дискретных случайных полей, которые с успехом применяются в моделировании различных текстур [1]. Однако, в случае моделирования изображений с однородными участками большого размера эти модели не в состоянии представить вариабельность и разнообразие кластерных конфигураций. Недавно был предложен подход, позволяющий устранить этот недостаток, связанный с поведением моделей марковских полей в тех случаях, когда параметры взаимодействия принимают большие значения. В работе [3] введена модель марковского поля связанных компонент, позволяющая выбором соответствующих параметров управлять количеством и размерами кластеров, и которая демонстрирует критическое поведение только в той части области параметров, для которой соответствующие модельные изображения не имеют практического интереса. Кроме того, модель марковского поля связанных компонент позволяет контролировать морфологические характеристики изображения, исключая «нежелательные» и давая

преимущество изображениям с кластерами подходящих форм.

Пусть D - множество пикселей (в частном случае D есть ограниченная прямоугольная решетка) и C – конечное множество цветов, где один из цветов есть цвет фона. Определим отношение соседства на D . В простейшем случае *соседними* являются пиксели, ближайшие по горизонтали или вертикали. Отношение связных компонент (СК) цветного изображения связывает два пикселя одного цвета, если существует цепочка из пикселей, связывающая эти два пикселя и состоящая из соседних пикселей одного и того же цвета. (Максимальное) множество пикселей, каждая пара из которых связана СК-отношением, т.е. СК-соседи, называется связной компонентой или кластером. Случайное поле $X = (X_i, i \in D)$ называется *марковским полем связных компонент*, если плотность функции распределения (относительно некоторой референс-меры) имеет вид

$$f(x) = Z^{-1} \prod_i \phi(x_{K_i}),$$

где $\phi(\cdot)$ - неотрицательная функция, такая что $u(x_{K_i}) = -\log(\phi(x_{K_i}))$ является потенциалом, соответствующим кластеру K_i , и Z - нормирующая константа.

Простым примером модели марковского поля связных компонент, которая позволяет моделировать кластерные конфигурации с большим разнообразием свойств, является модель с потенциальной функцией $u(x_{K_i}) = \theta$ для всех связных компонент K_i .

Построение карты мозаики контуров завершается этапом перераспределения пикселей фона между ближайшими кластерами. Мы предлагаем подход, аналогичный построению мозаики Вороного. В данном случае клетки мозаики строятся вокруг кластеров, сформированных на предыдущем этапе.

В [2] кластеры моделируются с помощью случайного поля независимых бинарных переменных. К сожалению, в этом случае реалистичные карты могут быть получены только в узком диапазоне изменения параметра модели, и, кроме того, возникает необходимость операции удаления мелких контуров, наличие которых не характерно для лесоустроительных карт. Предложенный подход, основанный на модели марковского поля связных компонент, лишен указанных недостатков, позволяя уже на этапе моделирования кластеров формировать реалистичные свойства моделируемого объекта.

Описанная модель случайной мозаики, свойства которой управляются небольшим числом параметров, может быть использована в качестве априорного распределения в задачах обработки изображений с

использованием байесовского подхода.

Работа выполнена при поддержке РФФИ (грант № 04-01-00622).

Литература

1. Винклер Г. Анализ изображений, случайные поля и динамические методы Монте-Карло. – Н.: Издательство СО РАН, филиал «Гео», 2002, 343с.
2. Грабарник П.Я., Смирнов В.Э., Сизов И.Е. Статистическое моделирование и анализ данных лесной таксации для задач оценки биоразнообразия // Лесоведение, 2004, №3, с. 35-43.
3. Moller, J. and Waagepetersen, R. Markov connected component fields // Adv. App. Prob., 1998, v. 30, pp. 1-36.

Метод анализа изображений для обнаружения объектов на статическом фоне

В.К. Де Ванса Викрамаратне

(Москва)

Описание задачи

Неподвижная цифровая видеокамера наблюдает за статичным (неизменным) фоном. Иногда на статичном фоне могут появляться посторонние объекты различной формы и размеров. Необходимо по изображениям, приходящим от камеры, автоматически обнаруживать наличие таких объектов.

Сложность задачи заключается в том, что с одной стороны посторонние объекты могут мало отличаться от фона, который они перекрывают, а с другой стороны, вследствие шума видеокамеры, изображение статичного фона даже в отсутствии посторонних объектов может существенно отличаться от кадра к кадру.

Изображение кадра представляют собой матрицу пикселей размера $H \times W$. Каждый пиксель кодируется целым числом, пропорциональным интенсивности этого пикселя. (Для простоты рассматриваются только монохромные изображения.) Минимальное значение интенсивности 0, максимальное – I_{\max} .

Итак, имеется K изображений статичного фона: F_1, F_2, \dots, F_K и одно тестируемое изображение T . Требуется обнаружить наличие посторонних объектов в изображении T .

Метод квадрата разности

Данный метод позволяет сравнивать два изображения и определять степень отличия между ними.

В качестве первого изображения берется усредненное изображение S

статического фона (таким образом, аддитивный шум уменьшается в K раз). Интенсивность каждого пикселя s_i этого изображения определяется как среднее арифметическое интенсивностей соответствующих пикселей изображений F_j :

$$s_i = \frac{1}{K} \sum_{j=1}^K f_i^j$$

$$i = 1, 2, \dots, H \times W,$$

где f_i^j - интенсивность i -того пикселя изображения F_j .

В качестве второго изображения берется тестовое изображение T .

Оба изображения одинаковым образом разбиваются на p возможно перекрывающихся частей – доменов. Для простоты используются прямоугольные домены. Число пикселей в каждом домене одинаково и равно s .

Далее, сравниваются соответствующие домены изображений S и T . Пусть D_i – i -тый домен изображения S , а D'_i – соответствующий ему домен изображения T . В качестве меры отличия M между двумя доменами берется сумма квадратов разностей соответствующих пикселей доменов:

$$M(D_i, D'_i) = \sum_{j=1}^s (d_j - d'_j)^2$$

$$i = 1, 2, \dots, p,$$

где d_j – интенсивность j -того пикселя домена D_S , d'_j – интенсивность j -того пикселя домена D_T .

Мера отличия $M(S, T)$ между изображениями S и T определяется как максимальная мера отличия между соответствующими доменами:

$$M(S, T) = \arg \max_i M(D_i, D'_i)$$

$$i = 1, 2, \dots, p,$$

Для принятия решения о том, есть ли посторонний объект на изображении T , выбирается некоторое пороговое значение M_0 . Если $M(S, T) \geq M_0$, то считается, что посторонний объект обнаружен. Если

$M(S, T) < M_0$, то считается, что посторонних объектов нет.

Улучшенный метод, основанный на статистическом подходе

Данный метод может использоваться всюду, где применим метод квадрата разности. Отличие заключается лишь на этапе вычисления меры отличия между двумя доменами $M(D_i, D'_i)$ и задания порогового значения M_0 .

Рассмотрим величину $\Delta'_j = d_j - d'_j, j = 1, 2, \dots, S$. Если в домене D_T постороннего объекта нет, то все значения Δ'_j определяются только шумом видеокамеры т.к. фон предполагается статичным. Каждое значение Δ'_j можно рассматривать как одно из наблюдений случайной величины Δ' . Таким образом, на каждый домен имеется S наблюдений. Необходимо проверить статистическую гипотезу о том, что распределение величины Δ' соответствует распределению шума камеры.

Распределение шума камеры в каждом домене может быть получено из K имеющихся изображений статического фона. Для каждого домена D_S , величина $\Delta_{j,i} = d_j - d_j^{F_i}$ ($i = 1, 2, \dots, K$; d_j – j -тый пиксель домена D_S , $d_j^{F_i}$ – интенсивность j -того пикселя соответствующего домена в изображении F_i) может рассматриваться как одно из $K \times S$ наблюдений величины Δ .

Для проверки согласия распределения величины Δ' с распределением Δ можно использовать критерий согласия Пирсона, описанный в [1]. Для этого следует задать уровень значимости ε . В качестве $M(D_i, D'_i)$ берется статистика Пирсона для выборки Δ' относительно распределения Δ , а в качестве M_0 – пороговое значение для статистики Пирсона (квантиль распределения χ^2), определяемое уровнем значимости ε .

Преимущества и недостатки улучшенного метода

Улучшенный метод использует детальную информацию о шуме камеры и, следовательно, более устойчив к шуму, чем метод квадрата разности.

В качестве параметра «чувствительности» можно использовать уровень значимости ε , вместо значения M_0 , которое существенно зависит от шума камеры.

К недостаткам можно отнести бóльшую вычислительную сложность по

сравнению с методом квадрата разности.

Литература

1. Манита А.Д. Теория вероятностей и математическая статистика: Учебное пособие // М.: Издат. отдел УНЦ ДО, 2001. С. 120.

Библиотека дискретных (логических) алгоритмов распознавания и классификации для параллельных компьютеров

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

В докладе рассматривается задача разработки программной библиотеки для решения задач распознавания и классификации с использованием методов комбинаторного (логического) анализа данных на параллельных компьютерах.

Введение

Дискретные (логические) алгоритмы, используемые для решения задач распознавания и классификации, являются достаточно трудоемкими в вычислительном плане, что накладывает ограничение на размерность решаемых задач. Для преодоления этого ограничения, с одной стороны, можно идти по пути совершенствования существующих алгоритмов и разработки новых, более эффективных алгоритмов. С другой стороны, можно идти по пути использования более совершенных вычислительных средств. В частности, достаточно разумным представляется использование многопроцессорных вычислительных комплексов.

Для большинства рассматриваемых алгоритмов распознавания и классификации достаточно легко сконструировать аналоги этих алгоритмов для параллельных компьютеров. Например, при построении множества представительных наборов наиболее существенная часть вычислительных ресурсов затрачивается на поиск покрытий булевой матрицы. В ряде случаев используется асимптотически оптимальный алгоритм поиска неприводимых покрытий булевой матрицы [1]. Особенностью этого алгоритма является порядок нахождения неприводимых покрытий: неприводимое покрытие находится тем раньше, чем меньше номера столбцов, входящих в него. Таким образом, для выполнения на суперкомпьютере алгоритма его модификация сводится лишь к делению исходной задачи на подзадачи. Например, на первом процессоре можно искать только покрытия, содержащие первый столбец, на втором процессоре искать покрытия, содержащие второй столбец и не содержащие первый и т.д. В рамках такой же достаточно простой стратегии распараллеливания можно реализовать еще ряд алгоритмов.

При решении прикладных задач первостепенным фактором является удобство использования алгоритмов при написании программ. Написание и отладка программ для параллельных компьютеров является достаточно сложным занятием и требует специфических навыков. Идеальным решением является создание библиотеки алгоритмов, которая избавляет пользователя от необходимости вникать в реализацию параллельного выполнения процессов на компьютере. Такая библиотека должна содержать полный спектр алгоритмов, начиная с алгоритмов предварительного анализа информации, и заканчивая алгоритмами для проверки качества работы построенных процедур распознавания. Немаловажным фактором так же является расширяемость такой библиотеки. Разработчик должен иметь возможность написать свой алгоритм и использовать его наравне с остальными алгоритмами из библиотеки.

Целью работы явилось создание библиотеки, отвечающей описанным выше требованиям.

Структура библиотеки

Библиотека представляет собой набор алгоритмов, реализованных на языке C++ для параллельных вычислительных комплексов, использующих интерфейс MPI[2].

Для наиболее сложных в вычислительном плане алгоритмов разработаны параллельные аналоги этих алгоритмов – алгоритмы, существенно использующие многопроцессорность (АСИМ). В частности сконструированы АСИМ, реализующие поиск покрытий булевых и целочисленных матриц, построение допустимых и максимальных конъюнкций логических функций, понижение значности исходной информации на основе корректного перекодирования, процедуры предварительной обработки данных, процедуры скользящего контроля.

В следующую группу входят алгоритмы, использующие АСИМ, но сами по себе не являющиеся сложными в вычислительном плане. К таким алгоритмам относятся алгоритмы голосования (по представительным/антипредставительным наборам, по покрытиям классов), тестовые алгоритмы (точный и приближенный), алгоритмы кластеризации, основанные на построении покрытий классов, алгоритмы распознавания, основанные на построении решающих деревьев.

В состав библиотеки также входят описания типов данных для математических объектов, используемых в алгоритмах, таких как матрица, элементарный классификатор, покрытие и т.д. Объектами данных типов оперируют алгоритмы библиотеки.

Техническая реализация

При выполнении программы в среде MPI все доступные процессы делятся на процесс-менеджер и вычислительные процессы.

На процесс-менеджер возлагаются следующие задачи: разбиение задач на подзадачи, контроль занятости вычислительных процессов и балансировка, сбор результатов решения подзадачи в окончательный ответ, выполнение прочих функций, не требующих значительных вычислений. Вычислительный процесс либо решает задачу, либо находится в режиме ожидания.

Каждый АСИМ состоит из двух частей – АСИМ-менеджера и АСИМ-калькулятора. АСИМ-менеджер выполняется в процессе-менеджере, а в вычислительных процессах выполняются АСИМ-калькуляторы. Запуск АСИМ осуществляется в процессе менеджера вызова АСИМ-менеджера. Процедура АСИМ-менеджера посредством MPI-сообщений активирует АСИМ-калькуляторы, объясняет задачу и раздает подзадачи. На выходе из процедуры АСИМ-менеджера все АСИМ-калькуляторы закрываются (вычислительные процессы переходят в режим ожидания).

Таким образом, использование АСИМ с точки зрения программиста не отличается от использования однопоточных алгоритмов. Логика программы не усложняется за счет использования многопроцессорности.

Работа выполнена при поддержке проектов РФФИ №№ 04-01-00795, 05-01-00495 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., 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
2. Message Passing Interface <http://www-unix.mcs.anl.gov/mpi/>

О сложности поиска оптимального в некотором смысле

АВО

А.А. Докукин

(Москва)

В предыдущих работах [1,2] автором рассматривалась задача построения оптимального в некотором смысле алгоритма для стандартной задачи распознавания [3]. В качестве параметрического семейства алгоритмов использовалось множество Алгоритмов Вычисления Оценок [3] и оптимизация проводилась одновременно по весам объектов обучающей выборки и порогам функции близости. При этом максимизировалась высота АВО на контрольной выборке, т.е. разница между минимальной оценкой, получаемой правильной парой (объект, класс), и максимальной оценкой, получаемой неправильной парой [4]. Здесь следует различать контрольную и тестовую выборки, поскольку контрольная используется на этапе обучения.

Были получены следующие результаты: оптимальные пороги не зависят от выбора весов объектов, при этом наличие оптимальных порогов позволяет выписать веса объектов в явном виде [1,2]. Кроме того, было показано, что для оптимизации порогов функции близости достаточно перебрать только конечное множество порогов, соответствующих правильным прямоугольникам вспомогательной задачи, и получена оценка их числа [5].

Здесь необходимо напомнить определения вспомогательной задачи и правильного прямоугольника.

Вспомогательная задача строится для поиска наилучших порогов функции близости при заданном контрольном объекте и обучающей выборке. Для каждой пары (S^i, S_j) объектов контрольной и обучающей выборки, соответственно, рассматривается вектор $T_{ij} = |S^i - S_j|$ покоординатных модулей разности этих векторов. Если объект S^i выделенный, то T_{ij} добавляется в новую задачу и относится в класс 1, если она правильная, т.е. S^i и S_j принадлежат одному классу, или в класс 0, если пара неправильная. Если же объект невыделенный, рассматриваются только неправильные пары и соответствующие им объекты T_{ij} также добавляются во вспомогательную задачу и относятся в класс 0. Правильным прямоугольником ранга k называется минимальный гиперпараллелепипед вида $[-\varepsilon_1, \varepsilon_1] \times \dots \times [-\varepsilon_n, \varepsilon_n]$ вспомогательной задачи, который содержит ровно k объектов класса 1.

Настоящая работа посвящена обоснованию необходимости перебора правильных прямоугольников. Рассмотрим самый простейший случай, когда объект описывается значением одного признака. Его отличительной особенностью является тот факт, что правильные прямоугольники образуют цепь. В этом случае задача поиска оптимального порога сводится к нахождению максимума функции $f(x) = x - g(x)$, заданной на конечном множестве точек $\{1, \dots, t\}$. Здесь $g(x)$ – некоторая монотонная функция, $0 \leq g(x) \leq G$. Точки $1, \dots, t$ в данном случае соответствуют правильным прямоугольникам или, что в одномерном случае равносильно, объектам класса 1 вспомогательной задачи. Функция $g(x)$ определяется количеством объектов класса 0, попадающих между соседними границами.

Очевидно, что в общем случае для нахождения максимума $f(x)$

необходимо знание ее значений во всех точках. Действительно, для любого подмножества из $t-1$ точек $1, \dots, t$, можно построить функцию $f(x)$, известную в этих точках, причем такую, что нельзя определить ее максимум на всем множестве.

Ниже мы покажем, что для восстановления функции $f(x)$ необходимо знание ее значений практически во всех точках. Пусть k - минимальное количество точек, которых достаточно для определения значения $f(x)$ на всем множестве $\{1, \dots, t\}$. Следующее утверждение получено совместно с профессором В.К. Леонтьевым.

Утверждение.

$$k \geq \frac{t \ln 2}{\ln t} - 2$$

Доказательство: Для получения необходимого условия воспользуемся соотношением между $n(k, t)$ - числом функций, которые можно различить, зная их значения в k точках из t , и $N(t)$ - числом всех монотонных функций, определенных на множестве из t точек:

$$n(k, t) \geq N(t) \quad (1).$$

Для простоты вычислений рассмотрим случай $G = t$ и воспользуемся оценками левой и правой части:

$$n(k, t) \leq C_t^k t^k \leq 2^t t^k,$$

$$N(t) = C_{2t}^t \geq \frac{2^{2t}}{\sqrt{2\pi t}}.$$

Заметим, что если выполнено неравенство (1), то, следовательно, выполнено и неравенство:

$$2^t t^k \geq \frac{2^{2t}}{\sqrt{2\pi t}},$$

откуда получаем оценку для k :

$$k \geq \frac{t \ln 2}{\ln t} - 2$$

Таким образом, доказано, что даже в простейшем случае, когда правильные прямоугольники образуют цепь, для восстановления значения

функции $f(x)$ на всем множестве $\{1, \dots, t\}$, необходимо знать ее значения практически во всех точках. Следовательно, перебор большей части правильных прямоугольников неизбежен.

Автор выражает признательность профессору Леонтьеву В.К. за неоценимую помощь.

Настоящая работа выполнена при поддержке грантов INTAS YSF 03-55-1969, а также РФФИ 02-01-00558, 03-01-00580 и госконтракта НШ-1721.2003.1 (научные школы).

Литература

1. Dokukin A.A. One approach for the optimization of Estimates calculating algorithms // International Journal on Information Theories and Applications. N 10. 2003. Sofia. Bulgaria. Pp. 463-467.
2. Докукин А.А. Об одном подходе к оптимизации АВО // Доклады 11-й Всероссийской конференции Математические методы распознавания образов ММРО-11. Москва. 2003. С. 68-71.
3. Журавлев Ю.И. Корректные алгебры над множеством некорректных (эвристических) алгоритмов II // Кибернетика, 1977, №6, стр. 21--27.
4. Журавлев Ю.И., Исаев И.В. Построение алгоритмов распознавания, корректных для заданной контрольной выборки // Ж. Выч. Мат. Мат. Физ., 1979, т. 19, №3.
5. Dokukin A.A. Optimal method for constructing AEC of maximal height in context of pattern recognition // Pattern recognition and image analysis, Vol. 15, No. 1, 2005.

Разработка нейросетевых алгоритмов анализа многомерных временных рядов и их применение при исследовании солнечно-земных связей

С.А. Доленко, Ю.В. Орлов, И.Г. Персианцев, Ю.С. Шугай
(Москва)

Введение

Авторами был разработан и реализован нейросетевой алгоритм прогнозирования временных рядов [1]. Разработанный алгоритм был применен для прогнозирования среднесуточной скорости солнечного ветра (СВ) на околоземной орбите. Существует заметная связь между наблюдаемой средней скоростью солнечного ветра и площадью корональных дыр (КД) на Солнце [3]. Спорадические процессы, происходящие на Солнце и влияющие на формирование потоков СВ, могут быть связаны, в частности, с активными областями [4]. Для выделения КД и активных областей на изображениях Солнца были проанализированы ежедневные снимки Солнца, сделанные телескопом EIT/SOHO [2].

Описание работы нейросетевого алгоритма

В данной работе используется модифицированная версия нейросетевого алгоритма прогнозирования событий во временных рядах [1], предназначенная для прогнозирования непрерывной величины.

В качестве входных данных рассмотрим многомерный временной ряд, который описывает изменение во времени значений каких-либо признаков, поведение которых связано с поведением объекта исследования. В данном случае один из таких признаков – значение суммарной площади экваториальных КД (рис. 1). Искомая величина (ИВ) представлена в виде одномерного временного ряда – скорость СВ на орбите Земли.

Будем предполагать, что на формирование величины скорости СВ влияет некое характерное поведение значения суммарной площади КД в течение некоторого времени, задаваемого из априорных соображений. Назовем такое характерное поведение входных данных явлением, а время, в течение которого оно длится, временем формирования ИВ.

Предположим также, что задан интервал поиска задержки между моментом, на который осуществляется прогнозирование ИВ, и возможным началом явления, влияющего на формирование ИВ. Будем предполагать, что время формирования ИВ много меньше длины интервала поиска.

При этом ставятся следующие задачи:

- нахождение внутри интервала поиска границ такого характерного поведения входных данных, которое влияет на формирование ИВ;
- прогнозирование самой ИВ.




Рис. 1. Схема алгоритма прогнозирования. Вверху – входные данные (суммарная площадь экваториальных КД); внизу – ИВ (скорость СВ на орбите Земли).

Для решения этих задач анализируемый интервал поиска разбивается на перекрывающиеся сегменты длиной, равной времени

формирования ИВ.

Для каждого такого сегмента строится отдельная нейронная сеть, обучающаяся прогнозировать значение ИВ на основе признаков в данном сегменте. Сдвигая интервал поиска по оси времени и применяя набор нейронных сетей к соответствующим сегментам анализируемого ряда, мы можем прогнозировать искомую величину скорости СВ.

По окончании обучения можно сделать вывод о том, что искомое характерное поведение входных данных наблюдается на участке той сети, которая по результатам обучения обеспечивает наиболее точный прогноз искомой величины скорости СВ.

Результаты прогнозирования среднесуточной скорости солнечного ветра по величинам площадей корональных дыр и активных областей

Комитет нейронных сетей обучался на данных (тренировочный набор), содержащих величины площадей КД и активных областей с января 1999 по июль 2003 года. В тестовый набор входили данные с июля 2003 года по декабрь 2003 года. Интервал поиска равнялся 14 суткам, время формирования ИВ - 7 суткам, а интервал перекрытия - 6 суткам. На рис. 2 представлены прогноз среднесуточной скорости СВ на 3 суток вперёд на независимых данных за 2004 год, а также результаты измерения скорости СВ на околоземной орбите за тот же период. Прерывание кривой прогноза связано с отсутствием данных со спутника (изображений Солнца). Величина коэффициента корреляции между измеренными и прогнозируемыми значениями скорости СВ за 2004 год равна 0.5.




Рис. 2. Прогнозируемые (пунктирная кривая) и измеренные (сплошная кривая) значения среднесуточной скорости солнечного ветра.

Заключение

Полученные результаты в целом хорошо согласуются с общими представлениями о формировании высокоскоростных потоков СВ [5]. Предложенный подход может дополнить существующие методики прогноза.

Для улучшения качества прогноза необходимо учитывать дополнительную информацию о процессах, происходящих на Солнце, а также о механизме распространения СВ в межпланетном пространстве.

Предлагаемая модифицированная версия нейросетевого алгоритма [1], предназначенная для прогнозирования непрерывной величины, показала свою работоспособность на реальных данных и может быть рекомендована для решения других задач прогнозирования временных рядов.

В случае высокой размерности входных данных алгоритм следует дополнить процедурой отбора существенных входных переменных.

Литература

1. Ju.S.Shugai et al. Neural network algorithm for events forecasting in multi-dimensional time series and its application for analysis of data in space physics // PRIA-7-2004, St.Petersburgh, Russia, October 18-23, 2004. Conference Proceedings. St.Petersburgh, 2004, v.3, pp.908-911.
2. I.G.Persiantsev, A.Yu.Ryazanov, Ju.S.Shugai. Automatic Processing and Analysis of Sequential Images of the Sun. // Ibid., pp.853-855.
3. Y.-M.Wang, N.R.Sheeley Solar wind speed and coronal flux-tube expansion // Astrophys. J., 1990, V.335, pp.726-732.
4. Веселовский И.С. и др. Глобальные изменения и асимметрия Солнца в период экстремально высокой активности в октябре-ноябре 2003 года // Астрон. вестн., 2005, т.39, № 2, с. 1-7.
5. C.N.Arge, V.J.Pizzo. Improvement in the prediction of solar wind conditions using near-real time solar magnetic field updates // J. Geophysical Research, 2000, V.105, pp.10465–10479.

Восстановление полутоновых изображений по изолиниям яркости

М.А. Домахин, Л.М. Местецкий, И.С. Мехедов, Л.Г. Петрова
(Москва)

Введение

Задача восстановления полутоновых изображений по изолиниям яркости возникает во многих приложениях в медицине, геоинформационных системах, в сжатии изображений. Задача сводится к интерполяции функции внутри некоторой многосвязной области по известным значениям ее на границе области. Мы рассматриваем в качестве многосвязной области многоугольную фигуру (многоугольник с дырами), граница которой состоит из одного внешнего многоугольника и некоторого множества внутренних многоугольников (рис. 1а). На внешнем граничном многоугольнике функция имеет одно значение, а на внутренних

граничных многоугольниках – другое.




Рис.1. Многосвязная многоугольная фигура, образованная изолиниями яркости (а) и ее диаграмма Вороного (б).

Визуально непрерывная интерполяция интерпретируется плавным переходом цвета от внешней границы области к внутренним границам (от одной изолинии яркости к другой). Трудность плавной закраски области состоит в построении наилучшей поверхности между ее внешней и внутренней границами в случаях, когда граничные многоугольники имеют сложную форму и взаиморасположение. В докладе предложен подход к решению задачи, основанный на скелетизации многоугольной фигуры [1].

Предлагаемое решение задачи включает в себя следующие этапы:

1. Построение диаграммы Вороного многоугольной фигуры;
2. Интерполяция функции в вершинах диаграммы Вороного;
3. Построение триангуляции многоугольной фигуры путем триангуляции областей Вороного;
4. Интерполяция функции внутри областей Вороного по триангуляции.

Построение диаграммы Вороного многоугольной фигуры

Диаграмма Вороного (ДВ) многоугольной фигуры строится в соответствии с алгоритмом, описанным в [1], имеющим вычислительную сложность $O(n \log n)$, где n – число вершин многоугольной фигуры, образованной смежными линиями уровня. ДВ представляет собой плоский граф (рис.1б), вершинами которого являются центры максимальных вписанных в многоугольную фигуру кругов, а ребрами – серединные оси фигуры. Ребра имеют вид сегментов прямых линий и парабол. В практических задачах сегменты парабол имеют относительно малую кривизну, что позволяет аппроксимировать их прямолинейными хордами парабол. В результате ДВ становится плоским прямолинейным графом.

Интерполяция функции в точках диаграммы Вороного

Первым шагом является вычисление значений функции в вершинах ДВ многоугольной фигуры. Вершинам, равноудаленным от разных граничных многоугольников, присваивается значение функции, равное среднему между значениями на внешней и внутренней границах. Такие вершины образуют циклические подграфы ДВ – «средние линии» фигуры (рис.2 а).




Рис.2. Интерполяция вдоль средних линий фигуры (жирная линия) и остальных ветвей (пунктирная линия) (а), покрытие ДВ треугольниками и трапециями (б).

Значения в остальных вершинах вычисляются с помощью линейной интерполяции между средними линиями и границами вдоль оставшихся (не циклических) подграфов в направлении от средних линий к границам:

$$f_v = \frac{r}{r+l} f_a + \frac{l}{r+l} f_b,$$

где f_a , f_b – значения функции на средней линии и соответствующей границе, r – удаленность точки от границы, l – удаленность точки от средней линии вдоль ветви ДВ.

Далее вдоль ребер ДВ вычисление функции осуществляется линейной интерполяцией между инцидентными вершинами ребер.

Построение триангуляции

Триангуляция многоугольной фигуры строится на основе ее ДВ. Из каждой вершины ДВ проводятся так называемые спицы – отрезки прямых, соединяющие вершины ДВ с ближайшими точками границы фигуры. В зависимости от типа ближайших точек (вершина фигуры или внутренняя точка стороны фигуры) с каждым ребром ДВ связывается пара из двух простых многоугольников: двух треугольников, либо треугольника и трапеции, либо двух трапеций (рис.2.б). Каждая из полученных трапеций после этого также разбивается на треугольники одной из своих диагоналей.

Линейная интерполяция яркости

Полученная триангуляция покрывает многоугольную фигуру. Поскольку во всех вершинах треугольников значения функции заданы, внутри треугольников функция вычисляется интерполяцией через барицентрические координаты точки. При закраске (заполнении) области на растровом устройстве возникает задача вычисления полученной функции во всех точках растра, попадающих внутрь многоугольной

фигуры. Для решения этой задачи разработан эффективный алгоритм, основанный на идее плоского заметания [2]. Горизонтальная заметающая прямая перемещается сверху вниз. Статус заметающей прямой включает список пересекаемых ею ребер триангуляции. Моментами критических событий являются прохождение прямой через вершины триангуляции и через строки растра. В первом случае происходит изменение статуса, а во втором – закраска точек растровой строки. Предложенный алгоритм позволяет осуществить закраску многоугольной фигуры очень быстро: в темпе простого сканирования точек растра по строкам.

Результаты

Предложенный алгоритм является эффективным. Он требует времени $O(n \log n + m)$, где n – число вершин многоугольной фигуры и m – число точек, в которых вычисляется функция. При закраске области на растре m есть число точек растра.

Алгоритм полностью реализован и проверен применительно к задаче сжатия полутоновых изображений с потерями. Сжатое изображение представляет собой набор изолиний с фиксированным уровнем яркости. В этом случае задача восстановления изображения в областях разности уровней яркости эффективно решается предложенным методом.

Работа выполнена при поддержке Российского фонда фундаментальных исследований, грант 05-01-00542.

Список литературы

1. Местецкий Л.М.; Скелет многосвязной многоугольной фигуры. Труды 15 международной конф. ГРАФИКОН-2005, Новосибирск, ИВМиМГ СО РАН, 2005, с. 242-249.
2. Препарата Ф., Шеймос М. Вычислительная геометрия: введение. Москва, Мир, 1989.

Прогнозирование разуплотненных зон в кристаллическом фундаменте на основе распознавания аномалий рассеянной компоненты сейсмического поля

А.С. Ермаков, В.Б. Левянт, В.В. Моттль

(Тула, Москва)

Сейсмические разведочные данные использовались до сих пор почти исключительно для разведки нефти и газа в осадочном покрове, слоистая структура которого ясно представлена на сейсмических разрезах. Истощение запасов нефти и газа в осадочных породах вызывает необходимость исследования массивных пород, прежде всего, в интервале нижележащего фундамента, где отсутствие слоистой структуры делает невозможным применение традиционных методов интерпретации данных

сейсмической разведки. Информацию о зонах повышенной пустотности, являющихся коллекторами флюидов, получают бурением дорогостоящих глубоких скважин, неизбежно редкая сеть которых не позволяет с достаточной надежностью распространить получаемые точечные оценки на весь объем исследуемого потенциального резервуара.

Результаты предварительных исследований [1,2] показывают, что различия в физических свойствах массивных пород вызывают заметные различия в трехмерной локальной текстуре рассеянной компоненты сейсмического поля [3] в окрестности соответствующего элемента пространственного массива данных.

Основная идея данной работы заключается в использовании принципа обучения распознаванию образов для совместной интерпретации прямой точечной информации о пространственном положении резервуаров, полученной из скважин, и косвенной информации из массива относительно дешевых сплошных пространственных данных сейсмической разведки (рис. 1 а, б, в), регистрируемого непосредственно на дневной поверхности. Локальные текстурные свойства сейсмического поля несут информацию о принадлежности каждой точки исследуемого подземного пространства к классу коллекторов или монокристаллических пород, а прямые скважинные данные могут служить в качестве информации учителя.

В данной работе была сделана попытка решить задачу предсказания количественной характеристики пористости - параметра общей пустотности ($акр$) на основании локальных текстурных свойств сейсмического поля - локальной энергии (LE), нерегулярности ($IRREG$) и высокочастотной составляющей спектра (HI), алгоритм вычисления которых предложен в [4].

Для установления количественной связи коэффициента общей пустотности с параметрами рассеянной компоненты использовалась модель регрессии:

$$акр(x, y, z) = a_0 + a_1y + a_2x + a_3z +$$

$$+ a_4LE(x, y, z) + a_5HI(x, y, z) + a_6IRREG(x, y, z) + \xi(x, y, z),$$

где $LE(x, y, z)$, $HI(x, y, z)$, $IRREG(x, y, z)$ значения параметров локальной текстуры сейсмического поля в соответствующей точке куба; a_0, \dots, a_6 - коэффициенты регрессии; $\xi(x, y, z)$ - аддитивный белый шум с нулевым средним. Использование в качестве параметров регрессии пространственных координат (x, y, z) , направлено на учет возможных линейных изменений зависимости $акр$ от параметров рассеянной компоненты при выделении достаточно протяженных аномалий.

Коэффициенты регрессии были получены, опираясь на значения $акр$ по всей длине более чем 100 скважин. Соответствие истинных значений коэффициента общей пористости $акр$ значениям, полученным в тех же точках по параметрам текстуры $акр_{расч}$, показано на рис. 2.а. Затем точки скважин по попаданию истинных значений $акр$ в один из четырех интервалов ($акр < 1\%$; $1\% \leq акр < 4\%$; $4\% \leq акр < 6\%$; $акр > 6\%$) были расклассифицированы на 4 категории, соответственно неколлекторы, промежуточные ячейки, коллекторы, ячейки с аномально высокими значениями $акр$.

На рис.2.б приведена гистограмма распределения $акр_{расч}$ для коллекторов с $акр 4\%-6\%$ (кривая 1) и неколлекторов с $акр < 1\%$ (кривая 2). На рис.2в иллюстрируется оценка вероятности правильного разделения коллекторских и неколлекторских ячеек (сплошная линия) по значениям $акр_{расч}$. Она равна для оценок типа «точка в точку» примерно 70%. На рис.2г характеризуется вклад в многомерную регрессию каждого параметра.




Рис. 1. Вертикальный разрез куба сейсмических данных: а) исходный разрез со своим частотным спектром, б) разрез после удаления регулярных волн, в) один из параметров локальной текстуры – локальная энергия

Полученная зависимость вероятности правильного распознавания коллекторских и неколлекторских ячеек от расчетной пористости (рис. 2.в) может быть использована в качестве входных данных для алгоритма учета априорной информации о взаимозависимости классов ячеек в едином массиве сейсмических данных, что должно позволить существенно снизить вероятность ошибки распознавания, и существенно повысить статистическую стабильность результата. Но уже на данном этапе правомерно будет картирование укрупненных коллекторских зон, приемлемое на поисково-разведочном этапе.

Работа выполнена при поддержке гранта № 04-010838 Российского Фонда Фундаментальных исследований.

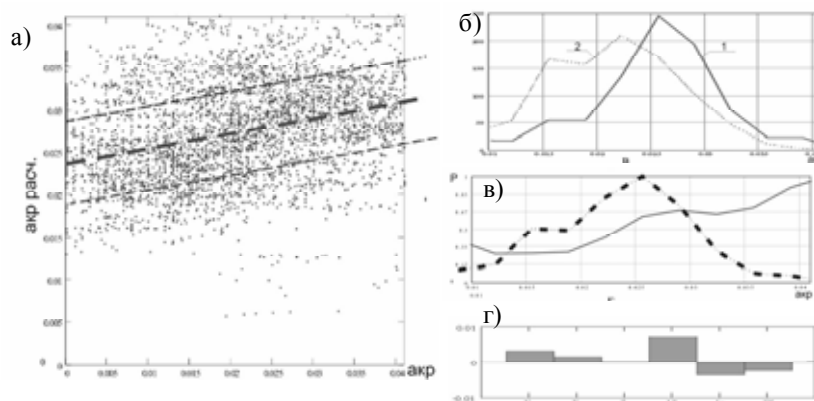


Рис. 2. К оценке количественной связи параметров локальной текстуры рассеянной компоненты: а) Соответствие истинных значений коэффициента общей пористости- $акр$ значениям, полученным в тех же точках по параметрам текстуры- $акр_{расч}$; б) гистограммы распределения $акр_{расч}$ для коллектора $0.04 < акр < 0.06$ и неколлектора $акр < 0.01$; в) вероятность выделения коллектора (пунктиром – плотность распределения числа точек для данного $акр_{расч}$; г) вклад факторов в расчетную пористость

Литература

1. Левянт В.Б., Моттль В.В. Способ сейсмической разведки массивных геологических пород. Патент на изобретение 2168187, 2001.
2. Антоненко М.Н. Моделирование прямой задачи сейсморазведки. XLIV Научная конференция МФТИ. М, 20001.
3. Левянт В.Б., Тронов Ю.А., Шустер В.Л. Использование рассеянной компоненты сейсмического поля для дифференциации кристаллического фундамента на коллекторские и моноклитные зоны. Геофизика, №3, 2003, с.17-26.
4. Левянт В.Б., Моттль В.В. Методика оценки параметров рассеянной компоненты 3^x-мерных сейсмических данных. Вестник РАН, секция наук о земле. 2002, №9.

Метод обработки вибрсейсмических сигналов для формирования сейсмограмм при использовании монохроматических зондирующих источников

С.А. Ефимов
(Новосибирск)

Аннотация

В докладе представлены результаты исследования возможности формирования качественных сейсмограмм при использовании

монохроматических зондирующих источников. Основным элементом предлагаемого метода является функциональный преобразователь данных. На примере двухслойной модели вибросейсмического эксперимента с нормальным стационарным шумом представлены результаты моделирования вибросейсмических сейсмограмм средствами пакета MathCAD. Основным результатом данного метода обработки сигналов является возможность «виртуального» расширения частотного диапазона источника сигнала.

Введение

Монохроматический зондирующий сигнал имеет ограниченное применение в технологии вибросейсмического исследования поверхности земли. Это обстоятельство, по мнению ведущих специалистов вибросейсмической технологии, определяется невозможностью построения временного годографа при использовании монохроматического зондирующего источника [1]. В данной работе на примере математической модели вибросейсмического эксперимента, разработанной средствами пакета Mathcad, показана возможность использования монохроматического зондирующего источника для формирования вибросейсмической сейсмограммы (виброграммы). При этом использованы подходы обработки сигналов, изложенные в работах [2,3,4]. Основная идея формирования виброграммы на основе монохроматического зондирующего источника заключается в том, что сигнал в точке регистрации, как совокупность монохроматических волн, преобразуется в совокупность узкополосных сигналов с аналогичными временами задержки. Аналитическое выражение преобразователя в операторной форме $\Psi(s)$ получено в работе [2] и представляет собой следующее выражение:

$$\Psi(s) = \frac{s^2 + \omega_k^2 \cdot (1 + (1 - \Delta) / (\exp(T_s \cdot s) - 1))}{s^2 + \omega_k^2}; \quad \alpha = 1 - \Delta; \quad \Delta = \omega_0^2 / \omega_k^2;$$

где ω_0 - частота монохроматического сигнала; ω_k - параметр преобразователя; T_s - время излучения источника.

Модель вибросейсмического эксперимента

Математическая модель экспериментальных записей сейсмических волн в точке регистрации во временном пространстве описывается выражением:

$$SS(t) = \sum_{i=1}^n A_i \cdot SBO(t - \tau_i)$$

где A_i - амплитуда i -ой волны; $SBO(t)$ - зондирующий сигнал в точке регистрации; n - количество волн; τ_i - время задержки i -ой волны;

Методы выделения времени вступления виброрейсмических волн

Реальные записи виброрейсмических экспериментов представлены в виде сигналов временного пространства. Поэтому при традиционной обработке сейсмических данных используется процедура свертки между сигналами, представленными во временном пространстве. В этом случае для формирования виброрейсмической сейсмограммы $VGT(t)$ используется преобразование:

$$VGT(t) = \int_{-\infty}^{\infty} SB(\tau) \cdot SS(t - \tau) d\tau;$$

где $SB(t)$ – модель зондирующего сигнала.

Это преобразование формирует при монохроматическом зондирующем сигнале виброграмму, в которой каждая волна представлена монохроматическим импульсом с огибающей в виде равнобедренного треугольника и длительностью $2T_s$. Это обстоятельство порождает проблему “корреляционных хвостов” и исключает возможность определения времени вступления волн. Для решения проблемы “корреляционных хвостов” предлагается ввести дополнительную процедуру свертки с использованием функции $\Psi(s)$. Тогда для формирования виброграммы $VGT(t)$ необходимо использовать преобразование:

$$VGT(t) = SS(t) \otimes \Psi(t) \otimes SB(t);$$

где $\Psi(t)$ - оригинал изображения $\Psi(s)$; \otimes - процедура свертки.

Моделирование эксперимента средствами пакета MathCAD

Модель виброрейсмического эксперимента с нормальным стационарным шумом для двух слоев отражения виброрейсмических волн представлена выражением:

$$SSN(t) = \sum_{i=1}^2 A_i \cdot SBO(t - \tau_i) + n(t);$$

где $SSN(t)$ - модель экспериментальных записей; $n(t)$ – сейсмический шум.

В дальнейшем использованы следующие обозначения параметров модели эксперимента: время сигнала $SBO(t)$ – T_s ; частота монохроматического сигнала $SBO(t)$ – f_0 ; параметр преобразователя $\Psi(s)$ – f_k ; время задержки сигнала $SBO_1(t)$ – τ_1 ; время задержки сигнала $SBO_2(t)$ – τ_2 , дисперсия шума – $D\{n(t)\}$. Рассмотрим результаты формирования виброграммы для случая волн с наложением во времени и следующих параметрах: $T_s = 3$ с; $f_0 = 2$ Гц; $f_k = 10$ Гц; $\tau_1 = 3$ с; $\tau_2 = 5$ с; $D\{n(t)\} = [0,1; 0,8]$; $A_1 = A_2 = 1$. Результаты формирования виброграммы для этих условий представлены на рис.1.

Анализ графиков временной виброграммы, формируемых на основе математической модели эксперимента при различных параметрах,

показывает: использование преобразователя $\Psi(s)$ приводит к улучшению корреляционной характеристики монохроматического зондирующего сигнала; улучшение корреляционной характеристики зондирующих сигналов эквивалентно «виртуальному» расширению частотного диапазона источника сигнала.




Рис. 1. Графики сигналов $SBO(t)$, $SSN(t)$ в точке регистрации, импульсная виброграмма $VGT(t)$ для случая малого (слева) и большого (справа) сейсмического шума

Автор выражает благодарность всем участникам семинаров отдела геофизической информатики ИВМиМГ за обсуждение проблем обработки геофизических данных. Работа выполнена при поддержке грантов РФФИ №03-05-64614, №03-05-65292.

Литература

1. Юшин В.И. Преобразование вибросейсмических сигналов при широкополосном и монохроматическом зондировании // Активная сейсмология с мощными вибрационными источниками / Отв. Ред. Г.М. Цибульчик. – Новосибирск: ИВМиМГ СО РАН, Филиал “Гео” Издательства СО РАН, 2004.
2. Ефимов С.А. Способ обработки для улучшения корреляционной характеристики зондирующих сигналов, применяемых при вибросейсмическом просвечивании земли для исследования структуры вулканов // Современные проблемы радиоэлектроники: Сб. науч. тр./ Под ред. А.И. Громыко, А.В.Сарафанова; Отв.за вып. В.И.Ризуненко. Красноярск: ИПЦ КГТУ, 2004.
1. Ефимов С.А. Метод оптимальной фильтрации зондирующих сигналов с частотной модуляцией в цифровых геофизических системах // Оптические методы исследования потоков: Труды VII Международной научно-технической конференции / Под ред. Ю.Н. Дубнишева, Б.С. Ринкевичуса. – М.: Издательство МЭИ, 2003 – 516 с.
1. Efimov S.A. Mathematical simulation of invariant seismic experiments for research into requirements of equivalence conditions of sounding signals. //

Особенности обработки вибросейсмических данных при формировании виброграмм в частотном пространстве

С.А. Ефимов
(Новосибирск)

Введение

Результатом вибросейсмического просвечивания земли является «фотография» земной коры в виде виброграммы. Она показывает времена пробега сейсмических волн, совокупность которых отражает структуру исследуемой области земной поверхности. Реальные экспериментальные записи вибросейсмических экспериментов представлены в виде сигналов временного пространства. Поэтому при традиционной обработке сейсмических данных используется процедура свертки между сигналами, представленными во временном пространстве. Альтернативным способом обработки вибросейсмических данных является процедура свертки тех же сигналов, представленных в частотном пространстве. На примере двухслойной модели вибросейсмического эксперимента показана тождественность использования процедуры свертки во временном и частотном пространствах.

Модель вибросейсмического эксперимента

Основным элементом технологии обработки вибросейсмических сигналов является определение времен пробега (задержки) сейсмических волн. Ключевым элементом вибросейсмических экспериментов является мощный источник зондирующего сигнала, формирующий сейсмическую волну с прецизионными параметрами. Стабильность параметров вибросейсмических волн дает возможность использовать в технологии обработки вибросейсмических сигналов математическую модель опорного сигнала для процедуры свертки. Математическая модель опорного сигнала наиболее популярного в вибросейсмической технологии исследования описывается выражением:

$$SBO(t - \tau_i) = \{ \Phi(t - \tau_i) - \Phi(t - \tau_i - T_s) \} \cdot \cos(\omega_0 \cdot t + \frac{\alpha}{2} \cdot t^2);$$

где ω_0 – начальная частота сигнала; α – скорость изменения частоты; τ_i – время задержки i -ой волны; T_s – время сигнала $SBO(t)$; $\Phi(t)$ – функция Хевисайда.

При $\tau_i = 0$ получаем математическую модель опорного сигнала $SB(t)$ для процедуры свертки. Математическая модель экспериментальных записей сейсмических волн в точке регистрации во временном пространстве описывается выражением:

$$SS(t) = \sum_{i=1}^n A_i \cdot SB_0(t - \tau_i)$$

где A_i – амплитуда i -ой волны; $SB_0(t)$ – зондирующий сигнал в точке регистрации; n – количество волн; τ_i – время задержки i -ой волны;

Математическая модель сигналов $SB_0(j\omega)$ и $SB(j\omega)$ в частотном пространстве формируется с помощью преобразования Фурье. Тогда математическая модель $SS(j\omega)$ экспериментальных записей в частотном пространстве формируется как сумма отдельных волн:

$$SS(j\omega) = SB_0(j\omega) \cdot (C_1 \cdot e^{-j\omega \cdot \tau_1} + C_2 \cdot e^{-j\omega \cdot \tau_2} + \dots + C_n \cdot e^{-j\omega \cdot \tau_n})$$

где C_i – амплитуда i -ой волны в частотном пространстве.

Методы выделения времени вступления вибросейсмических волн

При традиционной обработке сейсмических данных для формирования вибросейсмической сейсмограммы $VGT(t)$ используется преобразование:

$$VGT(t) = \int_{-\infty}^{\infty} SB(\tau) \cdot SS(t - \tau) d\tau;$$

где $SB(t)$ – модель зондирующего сигнала.

Другим способом обработки вибросейсмических данных является процедура свертки тех же сигналов, представленных в частотном пространстве. В этом случае для формирования частотной виброграммы $VGF(j\omega)$ используется преобразование:

$$VGF(j\omega) = \int_{-\infty}^{\infty} SB(j\omega) \cdot SS(j(\omega - \omega')) d\omega';$$

Моделирование эксперимента средствами пакета MathCAD

Модель вибросейсмического эксперимента с нормальным стационарным шумом для двух слоев отражения вибросейсмических волн представлена выражением:

$$SSN(t) = \sum_{i=1}^2 A_i \cdot SB_0(t - \tau_i) + n(t)$$

где $SSN(t)$ – модель экспериментальных записей; $n(t)$ – сейсмический шум.

Рассмотрим результаты формирования частотной и временной виброграммы для следующих параметров вибросейсмического эксперимента:

$$T_s = 3 \text{ с}; f_0 = 1 \text{ Гц}; f_k = 5 \text{ Гц}; \tau_1 = 2 \text{ с}; \tau_2 = 4 \text{ с}; D\{n(t)\} = 0,1; A_1 = A_2 = 1.$$

Сигналы $SB_0(t)$, $SS(t)$, $SSN(t)$, частотная и временная виброграммы для этих условий представлены на рис. 1.

Отличительной особенностью частотной виброграммы является зависимость масштаба абсцисс от параметра α сигнала $SB(t)$.

Функциональная зависимость времени вступления вибросейсмических волн от аргумента частотной виброграммы определяется следующим соотношением:

$$\tau_i = 2 \cdot \pi \cdot f_i / \alpha;$$

где f_i - частотный аргумент максимального значения виброграммы.

После масштабного преобразования оси абсцисс частотной виброграммы по этой формуле получаем независимость формы частотной виброграммы от параметра α . Результаты формирования частотной и временной виброграммы после масштабного преобразования представлены на рис.2.




Рис.1. Графики сигналов $SBO(t)$, $SS(t)$, $SSN(t)$ в точке регистрации, частотная и временная виброграммы.




Рис.2. Графики частотной и временной виброграммы после масштабирования

Заключение

Анализ графиков частотной и временной виброграммы, формируемых на основе математической модели вибросейсмического эксперимента при различных параметрах, показывает тождественность частотой и временной виброграммы. Автор выражает благодарность всем участникам семинаров отдела геофизической информатики ИВМиМГ за обсуждение проблем обработки геофизических данных. Работа выполнена при поддержке грантов РФФИ №03-05-64614, №03-05-65292.

Литература

1. Краснопецев Е.А. Математические методы физики. Избранные вопросы: Учебник. – Новосибирск: Изд-во НГТУ, 2003. – 244 с. – (Серия «Учебник НГТУ»).

Анализ и синтез контурных изображений на основе вейвлет-преобразования Хаара

А.А. Жарких, А.С. Юрко

(Мурманск)

Введение

Целью данного сообщения является представление методов выделения контуров, поиска и сравнения объектов в двумерных изображениях на основе вейвлетов Хаара.

Вейвлет-преобразование находит широкое применение в задачах обработки цифровых сигналов, в том числе очистки сигналов от шумов, распознавании образов, выделении характерных особенностей изображений. К числу характерных особенностей изображений относятся также и контуры объектов двумерных изображений.

Многие из существующих на сегодняшний день методик выделения контуров, поиска и сравнения объектов либо являются требовательными к вычислительным ресурсам, либо используют дополнительную информацию об особенностях исходного изображения. Поэтому разработка новых методов реализации указанных задач и в настоящее время представляет собой актуальную проблему.

Выделение контуров изображений

Последние 20 лет в теории и практике обработки сигналов активно исследуется вейвлет-преобразование [1][3][4]. Для решения разного рода задач используется множество базисов вейвлет-преобразования. В данной работе мы применяем самый простой вейвлет-базис – базис Хаара.

Вейвлеты нашли широкое применение во многих задачах компьютерной графики. Однако вейвлет-преобразование в классическом виде неинвариантно к аффинным преобразованиям и, следовательно, не может быть использовано для анализа данных. Как альтернатива – использование избыточного вейвлет-преобразования [6]. Данное преобразование имеет следующие преимущества перед классической схемой: инвариантность к сдвигу, учет локальных изменений яркости для каждой пары соседних пикселей изображения, отсутствие необходимости в изменении масштаба уточняющих коэффициентов для получения выходного контурного изображения. Главный недостаток: значительные вычислительные ресурсы.

Для выделения контуров объектов в двумерном изображении

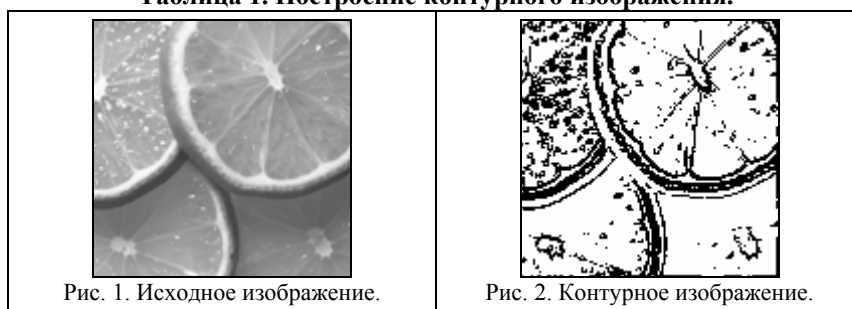
необходимо преобразовать модель RGB, в которой представлено исходное изображение, в модель HSV, а последующий расчет коэффициентов вейвлет-преобразования осуществляется только по компоненте яркости модели HSV. Компонента яркости выбрана по той причине, что контуры объектов совпадают с границами изменения яркости, определяемыми по ненулевым значениям уточняющих коэффициентов избыточного вейвлет-преобразования Хаара [2].

Кроме того, при выделении контуров объектов не требуется информация о цветовых компонентах. Таким образом, необходимо преобразовать цветное изображение в представление в виде серой шкалы – 256-градаций серого цвета [5].

Выделение контуров осуществляется на основе анализа значений уточняющих коэффициентов (высокочастотных составляющих) после проведения вейвлет-преобразования исходного изображения отдельно по строкам и отдельно по столбцам с дальнейшим объединением результатов работы алгоритма.

На рис. 2 представлено контурное изображение, полученное в результате работы описанного выше алгоритма применительно к исходному изображению на рис. 1.

Таблица 1. Построение контурного изображения.



Алгоритм поиска и сравнения объектов в двумерных изображениях

Непосредственно поиск и сравнение объектов осуществляется на основе анализа низкочастотных коэффициентов, полученных в результате вейвлет-преобразования. Ниже приведено краткое описание алгоритма:

1. Расчет границ контурного объекта.
2. Расчет количества совпадающих пикселей (процент схожести) для низкочастотных коэффициентов текущего шага вейвлет-синтеза.
3. Смещение контурного объекта и изменение его масштаба отдельно по строкам и столбцам (если возможно). Если возможно, то шаг 2.
4. Определение новой позиции объекта и его масштаба.
5. Очередной шаг вейвлет-синтеза. Шаг 2.

Таким образом, в результате работы данного алгоритма осуществляется сравнение и поиск объектов, имеющих разный масштаб и смещенных друг относительно друга.

Результаты сравнения и поиска изображений

Процент схожести изображений на рис. 3 и рис. 4 (смещенных друг относительно друга) равен 100% при выполнении описанного выше алгоритма для четырех последних шагов вейвлет-синтеза изображений.

Таблица 2. Сравнение изображений.



В таблице 4 содержится информация о положении объекта на рис. 5 относительно искомого объекта на рис. 6, а также о его масштабе по осям x и y для каждого шага вейвлет-синтеза.

Таблица 3. Поиск объектов.




Таблица 4. Пошаговое сравнение изображений.

Шаг	Смещение по x	Смещение по y	Масштаб по x	Масштаб по y	Процент схожести
2	18	19	1,23	1,29	100
1	35	38	1,28	1,15	100
0	71	75	1,27	1,15	100

Заключение

В данной работе описаны методы выделения контуров, поиска и сравнения объектов в двумерных изображениях. Предложенный алгоритм

сравнения и поиска изображений позволяет сократить вычислительные ресурсы за счет использования на последующих шагах вейвлет-синтеза (при большем разрешении) информации, полученной на предыдущих шагах (при меньшем разрешении). Кроме того, указанный алгоритм сравнения инвариантен к смещению и изменению масштаба.

Остается открытым вопрос о выборе количества шагов вейвлет-преобразования. Чем меньше это значение, тем дольше будет выполняться процедура сравнения (проверка масштаба и смещения может осуществляться довольно долго), однако результат сравнения будет более точным. Чем больше это значение, тем меньше вероятность получения правильной оценки (на начальном шаге будут сравниваться изображения, не содержащие достаточной информации о деталях объектов), однако процедура сравнения будет выполнена достаточно быстро. Оптимальным для изображения с разрешением 128x128 является выбор двух или трех шагов вейвлет-преобразования.

Литература

1. Воробьев В.И., Грибунин В.Г. Теория и практика вейвлет-преобразования. Военный университет связи, Санкт-Петербург, 1999, 180 с.
2. Плекин В.Я., Малышев А.В. Алгоритм распознавания изображений с использованием вейвлет-преобразования. 3-я Международная Конференция DSPA-2000.
3. Столниц Э., ДеРоуз Т., Салезин Д. Вейвлеты в компьютерной графике: Пер. с англ. – Ижевск: НИЦ «Регулярная и хаотическая динамика», 2002, 272 с.
4. Шитов А.Б. Разработка численных методов и программ, связанных с применением вейвлет-анализа для моделирования и обработки экспериментальных данных. Диссертация на соискание ученой степени кандидата физико-математических наук. Ивановский государственный университет, Иваново, 2001, 125 с.
5. Южиков В. Бинаризация растровых изображений, 2004 г., <http://www.devkhit.ksu.ru>.
6. Andrew P. Bradley, "Shift-invariance in the Discrete Wavelet Transform", Digital Image Computing: Techniques and Applications (DICTA'03), Sydney, Australia, December 2003, pp 29-38.
7. Zharkikh A.A., Dmitriev M.M., Yurko A.S.. Effective image coding in low quality data transmission system. Proceedings of Conference "Seventh International Conference on Pattern Recognition and Image Analysis: New Information Technologies (PRIA-7-2004)", S-Pb, Russia 18-23 October 2004, Vol. 2, pp. 572 – 575.

Итеративный морфологический алгоритм локализации в реальном времени неизвестного объекта на изображении

Г.С. Животников, Ю.П. Пытьев, И.И. Фаломкин

(Москва)

Одна из часто решаемых задач анализа изображений – задача локализации объекта на изображении. Будем предполагать, что предъявляются два изображения. Одно из них – фоновое – представляет собой изображение некоторой сцены, а второе – анализируемое – представляет собой изображение сцены, полученной из предыдущей добавлением априори неизвестных объектов. Задача локализации состоит в нахождении «неискаженной» добавленными объектами области анализируемого изображения.

Решение такой задачи существенно затрудняется следующими обстоятельствами: во-первых, между моментами получения фонового и анализируемого изображений условия их регистрации могут существенно измениться. Во-вторых, на анализируемом изображении практически всегда присутствует шум, обусловленный неидеальностью регистрирующего прибора. Эти обстоятельства являются причиной того, что анализируемое изображение может кардинально отличаться от фонового даже в тех областях, в которых отсутствуют добавленные объекты. Кроме того, многие практические приложения, например, анализа видеоданных в реальном масштабе времени, накладывают ограничения на вычислительную сложность алгоритма.

В работах [1-3] представлены математические методы морфологического анализа изображений, позволяющие эффективно решать поставленную задачу в том случае, когда изображения добавленных объектов занимают относительно малую часть поля зрения. В противном случае, указанные методы позволяют надежно судить лишь о наличии или отсутствии новых объектов на изображении, но не позволяют локализовать их.

В работе [4] предложен алгоритм морфологической фильтрации изображений, позволяющий решать задачу локализации объектов и в том случае, когда объект занимает существенную часть поля зрения. Однако алгоритм морфологической фильтрации не позволяет локализовать «слабо текстурированные» объекты и имеет высокую вычислительную сложность.

В докладе предлагается итеративный морфологический алгоритм позволяющий локализовать «слабо текстурированные» объекты, занимающие существенную часть поля зрения, и имеющий низкую вычислительную сложность ($O(N)$, где N — размерность изображения), приемлемую для приложений реального масштаба времени (таких как анализ последовательностей изображений размерности $320*240$ точек,

поступающих от телекамеры с частотой 30 кадров в секунду), работающих на современных ЭВМ. Результатом работы данного алгоритма является оценка подмножества поля зрения, на котором анализируемое изображение, возможно искаженное условиями регистрации, «не искажено по форме» добавленными объектами.



Рис. 1. Изображения, использованные в вычислительных экспериментах А и Б. Слева направо: изображение фона, анализируемые изображения для экспериментов А, Б.



Рис. 2. Результат вычислительного эксперимента А. Представлены результаты работы следующих алгоритмов (слева направо): морфологического, морфологической фильтрации, итеративного морфологического.



Рис. 3. Результат вычислительного эксперимента Б. Представлены результаты работы следующих алгоритмов (слева направо): морфологического, морфологической фильтрации, итеративного морфологического.

На каждой итерации предлагаемого алгоритма оцениваются возможные изменения условий регистрации и находится подмножество поля зрения, на котором фоновое изображение, будучи преобразованным согласно найденным изменениям условий регистрации, достаточно точно

приближает анализируемое. Найденное подмножество используется на следующей итерации для более точного оценивания возможных изменений условий регистрации. На первой итерации в качестве такого подмножества используется все поле зрения. В том случае, если алгоритм должен иметь фиксированную вычислительную сложность, количество необходимых для построения оценки итераций фиксируется. В противном случае, итерации можно повторять до тех пор, пока найденное подмножество перестанет изменяться. На практике, для удовлетворительного решения задачи локализации достаточно трех-четырёх итераций.

Сравнение итеративного алгоритма с морфологическим алгоритмом и алгоритмом морфологической фильтрации было проведено в вычислительных экспериментах А и Б, отличающихся размерами добавленных объектов на изображениях: в эксперименте А размер объекта мал по сравнению с полем зрения, в то время как в эксперименте Б объект занимает значительную часть всего изображения. На рисунке 1 представлены изображения, использованные в указанных экспериментах. Заметим, что условия регистрации изображений без добавленных объектов и с добавленными объектами существенно различаются. На рисунке 2 представлены результаты вычислительного эксперимента А. Все три сравниваемых алгоритма удовлетворительно справились с задачей. При этом если принять время выполнения традиционного морфологического алгоритма за единицу, то время выполнения итеративного алгоритма составило примерно 4 единицы, а алгоритма морфологической фильтрации – 500 единиц. На рисунке 3 представлены результаты вычислительного эксперимента Б. Как можно видеть, морфологический алгоритм не справился с локализацией объекта, занимающего значительную часть поля зрения. Алгоритм морфологической фильтрации ошибочно включил в «неискаженную» добавленными объектами область «слабо текстурированные» части объектов. Предлагаемый алгоритм показал хорошее качество решения поставленной задачи. Время, необходимое для обработки итеративным морфологическим алгоритмом одного изображения размерности 320*240, составляет порядка 10 мс на ЭВМ, оснащенной микропроцессором Intel Pentium 4; это время достаточно мало и позволяет осуществлять анализ видеопоследовательностей в реальном времени.

Работа выполнена при финансовой поддержке РФФИ, грант №05-01-00615.

Литература

1. Пытьев Ю.П. Морфологический анализ изображений // ДАН СССР, 1983, т.269, №5, с.1061-1064.
2. Пытьев Ю.П. Задачи морфологического анализа изображений // В

- сборнике статей «Математические методы исследования природных ресурсов Земли из космоса». М.:Наука, 1984, с.41-82.
3. Pyt'ev Yu. P. Morphological image analysis //Pattern Recognition and Image Analysis, vol.3, №1, p.19-28, 1993.
 4. Животников Г.С., Пытьев Ю.П., Фаломкин И.И. Об алгоритме фильтрации кусочно-постоянных изображений //М., «Интеллектуальные системы», в печати.

Биометрическая идентификация по линии профиля на основе гранично-скелетного представления

К.В. Жукова, И.А. Рейер

(Москва)

Интерес к процессам узнавания и идентификации человека по каким-либо признакам всегда был значительным, особенно в связи с возрастающими практическими потребностями (системы охраны, верификация кредитных карточек, криминалистическая экспертиза и т.д.) Сегодня широкое распространение получают биометрические системы идентификации, основанные на уникальных биологических характеристиках, которые трудно подделать, и которые однозначно определяют конкретного человека. К таким характеристикам относятся отпечатки пальцев, форма ладони, узор радужной оболочки и сетчатки глаза, а также лицо человека.

Ранее неоднократно рассматривались задачи распознавания по изображению в фас. Однако в известных работах не уделялось внимание распознаванию по профилю, который тоже является индивидуальной биологической характеристикой человеческого лица. В настоящей работе представлен подход к идентификации лица по линии профиля. Отличительной чертой данного подхода является использование непрерывной гранично-скелетной модели изображения [1]. Это позволяет более эффективно и качественно выделять элементы образа по сравнению с традиционными растровыми алгоритмами.

Метод включает в себя несколько этапов: выделение линии профиля на изображении, сравнение профилей и распознавание.

Из исходного цветного или полутонового изображения линия профиля выделяется следующим образом (рис. 1). Сначала исходное изображение преобразуется в бинарное изображение головы с помощью методов яркостной или цветовой сегментации [2,3]. Далее строится непрерывная гранично-скелетная модель растрового образа [1]. Эта модель состоит из границы многоугольной фигуры, разбивающей плоскость дискретного изображения на фигурную (содержащую все черные точки) и фоновую (содержащую все белые точки) компоненты, и базовых скелетов фигурной и фоновой компонент. Элементы базового скелета определяют

фундаментальные свойства структуры образа. Характерным деталям линии профиля (лбу, переносице, носу, губам, подбородку и т.д.) будут соответствовать отдельные ветви базовых скелетов фигурной и фоновой компонент изображения головы. Совместный анализ расположения фигурных и фоновых ветвей позволяет корректно выделить участок границы многоугольной фигуры, соответствующий линии профиля. Таким образом, получаем представление профиля в виде ломаной.




Рис. 1.

Полученная линия профиля сравнивается с эталонными линиями при помощи одного из методов вычисления меры различия между ломаными (см., например, [4,5,6]), и на основе полученных значений меры проводится идентификация (например, по методу k ближайших соседей).

Для проведения экспериментов по оценке эффективности предлагаемого подхода была создана база профилей. База содержит цветные изображения 10 человек (в профиль, на одинаковом фоне, при одинаковом освещении), по 8 фотографий на каждого человека. Изображения одного человека отличаются друг от друга положением головы (изменение наклона, небольшие повороты).

Сравнение профилей проводилось с использованием механической модели, описывающей деформацию ломаных путем растяжения и изгиба [6]. Мерой различия между профилями является минимальная величина работы по преобразованию одного профиля в другой на основе такой деформации. Данная модель имеет один параметр настройки – коэффициент работы k_w . Для распознавания профилей применялся метод k ближайших соседей.




Рис. 2.

Были проведены несколько серий экспериментов: исследование чувствительности метода к изменению параметров настройки (k_w и k) и оптимизация этих параметров; исследование чувствительности метода к вариации исходных данных (к изменению числа классов в базе, числа прецедентов в классе, к мимике).

Для нахождения оптимальных настроек метода были вычислены меры сходства профилей при различных значениях $k_w \in (0,1]$ и построена зависимость числа правильно распознанных объектов R от значений k и k_w . На рис. 2 показаны линии уровня R . При найденных оптимальных значениях параметров настройки качество распознавания составляет 96.3%.

Исследование чувствительности метода к вариации исходных данных включало три типа экспериментов.

а) Проводились исследования, аналогичные описанным выше, но в качестве базы прецедентов использовалась база с меньшим количеством классов. В таблице 1 представлены полученные результаты.

Таблица 1.

Число классов в базе	Наилучшее число соседей, k	Наилучшее значение коэффициента k_w	Процент правильно распознанных объектов
10	2, 3	0.12–0.2	96.3%
9	2, 3	0.05–0.18	95.8%
8	2, 3	0.05–0.22	95.3%
7	2	0.02–0.22	96.4%
6	2	0.02–0.25	95.8%
5	2, 3	0.02–0.25	95%

Из таблицы видно, что оптимальные диапазоны значений параметров и процентное отношение правильных распознаваний изменяются незначительно.

б) В следующем эксперименте оптимизация проводилась при уменьшении количества профилей в каждом классе базы. Полученные результаты представлены в таблице 2. Как и в предыдущем случае, оптимальные диапазоны значений параметров и процентное отношение правильных распознаваний изменяются незначительно.

Таблица 2.

Число объектов в каждом классе	Наилучшее число соседей, k	Наилучшее значение коэффициента k_w	Процент правильно распознанных объектов
8	2, 3	0.12–0.2	96.3%
7	3	0.15	94.2%
6	2	0.12–0.18	93.3%

в) Для исследования чувствительности метода к мимике была создана дополнительная база профилей. В ней содержатся 10 классов по 8 профилей в каждом. При этом фотографируемые люди заметно изменяли выражение лица (рис. 3).



Рис. 3.

Были проведены эксперименты по нахождению оптимальных значений параметров настройки и вычислению качества распознавания. На рис. 4 показаны линии уровня R .




Рис. 4.

В результате получены следующие значения: $k = 2,3$; $k_w \in [0.05, 0.1]$; процент правильно распознанных объектов - 85%. Как видим, результат распознавания хуже, чем при анализе первой базы, и при проведении сравнения необходимо учитывать влияние мимики.

Тем не менее, можно утверждать, что форма профиля лица действительно является достаточно информативной характеристикой для идентификации человека. Применение непрерывной гранично-скелетной модели позволяет эффективно выделить линию профиля на изображении и провести анализ формы линии. Описанная методика распознавания может быть использована при разработке промышленных систем биометрической идентификации.

Работа выполнена при поддержке Российского Фонда фундаментальных исследований (РФФИ), проекты 04-01-08058 и 05-07-90395.

Литература

1. Местецкий Л.М., Рейер И.А. Непрерывная гранично-скелетная модель дискретного изображения с контролируемой точностью аппроксимации // Доклады XI Всероссийской конференции «Математические методы распознавания образов» (ММРО-11). Москва, 2003. С. 367-371.
2. Pratt W.K. Digital image processing. John Wiley & Sons, New York, 2001.
3. The colour image processing handbook. Chapman & Hall, London, 1998.
4. Arkin E.M. et al. An efficiently computable metric for comparing polygonal shapes. IEEE Trans. PAMI, 13(3), Mar 1991.
5. Sederberg T., Greenwood E. A physically based approach to 2D shape blending. In Computer Graphics (SIGGRAPH '92 Proceedings), vol. 26, 1992, pp. 25-34.
6. Рейер И.А. Распознавание формы плоских объектов на основе гомеоморфного отображения границы // Труды 5-й международной конференции «Распознавание образов и анализ изображений: новые информационные технологии» (РОАИ-5-200). Самара, 2000. С. 377-381.

Система распознавания интеллектуальных заимствований «Антиплагиат»

Ю.И. Журавлев, К.В. Рудаков, А.С. Инякин, А.А. Кирсанов, А.В. Лисица, Г.В. Никитов, Н.В. Песков, М.Ю. Романов, Ю.В. Чехович, Р.И. Яминов
(Москва)

В настоящее время развитие и популяризация всемирной сети Интернет происходит все более быстрыми темпами. Наряду с неоспоримыми преимуществами, которые обеспечиваются использованием Интернета в рамках учебного процесса, существует также и ряд определенных недостатков. К таковым относится возможность

использования его ресурсов учащимися в качестве источника плагиата при подготовке рефератов, курсовых, дипломных работ и других заданий, в которых от них требуется самостоятельная и творческая деятельность. Выявление случаев использования Интернета таким «неправомерным» способом является сложной, трудоемкой задачей, и без привлечения специальных технических средств она оказывается практически неразрешимой. Разработка инструментария для обнаружения плагиата в текстах учащихся ведется за рубежом в течение последних десяти лет, и в этом направлении достигнуты определенные успехи. Однако инструментария, работающего с русскоязычными текстами и находящего источники цитирования в российском сегменте Интернета, до сих пор создано не было. В докладе представлена система автоматической проверки текстов на наличие заимствований «Антиплагиат» (Система), представляющая собой такой инструментарий.

Структура и технические характеристики Системы обусловлены главным функциональным требованием: обеспечить пользователей удобным, быстрым и доступным web-сервисом для высококачественной проверки документов на наличие заимствований.

Архитектура системы

Функционально Система состоит из трех основных частей (рис. 1): подсистемы формирования области поиска источников цитирования, подсистемы, осуществляющей проверку степени оригинальности пользовательских документов, и подсистемы, реализующей пользовательский интерфейс.

Область поиска источников представляет собой базу данных, в которой хранятся тексты, преобразованные в определенный формат, а ее заполнение и обновление производится в регламентированном режиме при помощи специального модуля – робота.

Подсистема проверки пользовательских документов состоит из модуля преобразования файлов из различных форматов (doc, rtf, pdf, html, zip и других) в текстовый вид, модуля анализа текста на наличие заимствований и модуля генерации отчета о результатах анализа.

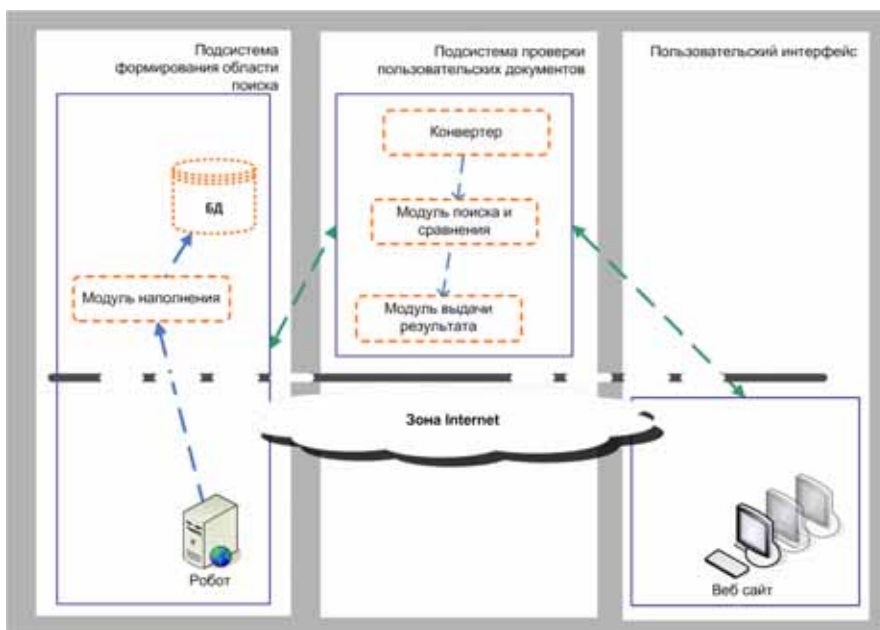


Рис. 1. Схематическая структура Системы.

Пользовательский интерфейс Системы реализован в виде Интернет-сайта, где после регистрации пользователь получает доступ к ее сервисам по защищенному протоколу передачи данных, среди которых находятся загрузка файлов на проверку, просмотр полученных ранее результатов, быстрая проверка коротких частей текста, просмотр сопроводительной документации и другие.

Технология проверки

На первом этапе Система собирает информацию из различных источников: загружает из Интернета и обрабатывает сайты, находящиеся в открытом доступе, базы научных статей и рефератов. Загруженные документы проходят процедуру фильтрации, в результате которой отбрасывается бесполезная с точки зрения потенциального цитирования информация (это касается в первую очередь HTML-страниц с большим количеством рекламы, новостных заголовков, меню и так далее).

На следующем этапе каждый из полученных таким образом текстов определенным образом форматируется и заносится в системную базу данных. Кроме того, в общую базу текстов поступают документы, загруженные на проверку пользователем, если такая возможность была разрешена им во время процедуры загрузки.

Все пользовательские документы, загружаемые для проверки, ставятся в очередь на обработку. Эффективная структура хранилища данных и

проведенная оптимизация алгоритмической части Системы позволяют осуществлять проверку документа среднего размера в течение нескольких секунд.

Наконец, после успешной проверки документа, пользователь получает доступ к отчету, в котором в наглядной форме представляются ее результаты. Структура отчета позволяет выделять в проверяемом тексте заимствованные части как по всем источникам, так и по их любому подмножеству.

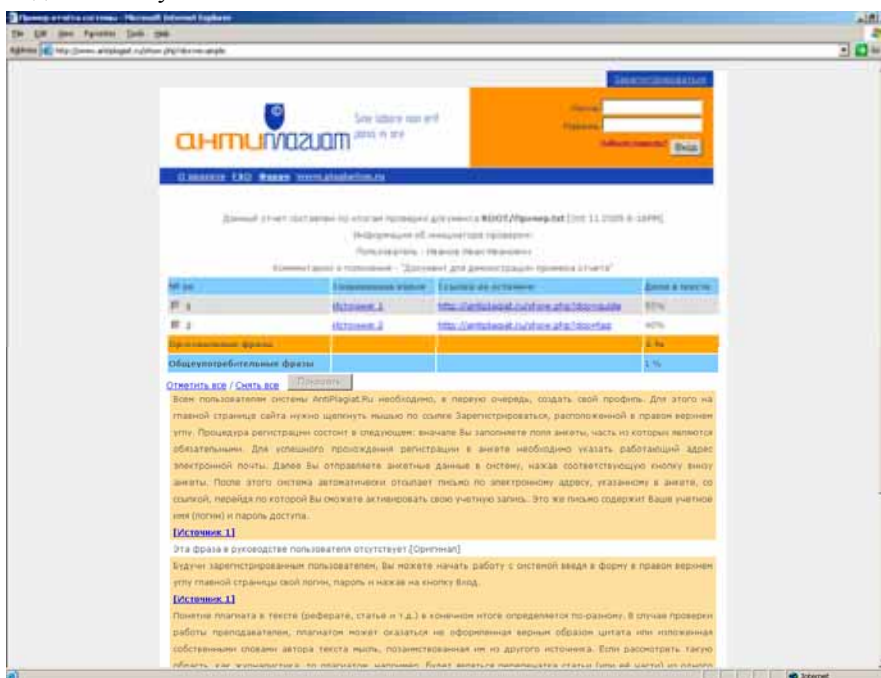


Рис. 2. Пример отчета по обработанному документу.

В настоящий момент ведется опытная эксплуатация Системы. Доступ к сервисам Системы можно получить зайдя на сайт www.antiplagiart.ru.

Работа выполнена при поддержке Программы РАН «Поддержка инноваций».

Поиск особых точек на молекулярных поверхностях с использованием нечеткого кластер-анализа.

А.М. Захаров, И.В. Свитанько, С.С. Григорьева, В.Т. Чичуа
(Москва)

В работе предложен новый алгоритм поиска особых точек на молекулярных поверхностях. Преимуществом алгоритма является возможность принимать во внимание как геометрические, так и локальные физико-химические свойства поверхности. Изменяя параметры алгоритма, можно изменять число особых точек и критерии их отбора.

Постановка задачи

В молекулярном докинге - процессе вычислительного моделирования взаимодействия двух молекул – широко используется введенное Ли и Ричардсом[1] понятие молекулярной поверхности – поверхности, особым образом «натянутой» на пространственный молекулярный граф[2]. При этом, как правило, на молекулярную поверхность «наносится» какое-либо физико-химическое свойство (например, потенциал электростатического взаимодействия в каждой точке поверхности).

Важной проблемой как в задаче докинга, так и в задаче «структура-свойство» вообще является выделение на молекулярной поверхности особых точек – базовых фрагментов описания молекулы, используемых в дальнейшем для предсказания ее свойств или результатов взаимодействия с другими молекулами. Существующие методы, как правило, служат для выделения геометрических особенностей поверхности (например, выпуклостей). Целью данной работы является разработка более универсальных способов поиска и классификации особых точек.

Будем считать, что задана некоторая выборка, состоящая из N триангулированных молекулярных поверхностей $S_i, i = 1, \dots, N$ (т.е., каждая поверхность представлена графом – набором точек в пространстве, соединенных треугольной сеткой), причем для каждой точки известен некоторый набор ее физико-химических свойств, представляемый вектором из m численных значений. Требуется выбрать на этих поверхностях особые точки и классифицировать их каким-либо образом, тем самым, получив описание каждой молекулы в виде набора «маркированных» точек.

Метод решения

Вначале опишем для каждой из точек (триангулированных) поверхностей геометрию поверхности вблизи нее. Для этого будем использовать функцию Коннолли[3], определяемую в точке P гладкой поверхности M , являющейся границей области Ω , $\partial\Omega = M$, как

$$C(P, r) = \frac{\iint ds}{r^2},$$

где r – изменяемый параметр (радиус сферы $S = S(P, r)$ с центром в точке P). Функция Коннолли принимает значения в интервале $(0, 4\pi)$ и легко видеть, что большие значения функции $C(P, r)$ соответствуют «вогнутым» областям поверхности, а меньшие – выпуклым. В рамках данной работы мы будем описывать геометрию поверхности в точке при помощи набора значений функции Коннолли, вычисленных для различных радиусов r_1, r_2, \dots, r_n сферы S , $r_1 < r_2 < \dots < r_n$. Тем самым, каждой точке $P \in M$ сопоставляется вектор $(C(P, r_1), \dots, C(P, r_n))$, характеризующий геометрию поверхности вблизи точки.

Достоинством такого подхода является то, что поверхность в каждой точке описывается в разных масштабах. Значения функции Коннолли для небольших радиусов r характеризуют локальную форму поверхности, а при увеличении радиуса – геометрию на большем удалении от точки.

Итак, теперь для каждой точки поверхности известны m физико-химических свойств, заданных в постановке задачи и n значений функции Коннолли – т.е., в каждой точке задан $m + n$ -мерный вектор свойств. Соберем вместе все такие вектора для всех точек на всех поверхностях выборки и обработаем полученное множество каким-либо из методов кластер анализа (предварительно, возможно, задав метрику в пространстве R^{m+n}).




Рис.1. Молекулярная поверхность с выделенными особыми точками.

В итоге, каждая поверхность будет разбита на (вообще говоря, нечеткие) области согласно кластерам (маркировке) особых точек. Далее, в качестве особых точек можно взять центры соответствующих областей и

присвоить полученным точкам «имена» соответственно номеру кластера.

Выше приведен пример обработки молекулярной поверхности: с помощью кластер-анализа выделены «выпуклые» и «вогнутые» участки и обозначены особые точки.

Литература

1. Lee, B. and F. M. Richards. The interpretation of protein structures: Estimation of static accessibility. / J. Mol. Biol. 1971, №55, pp.379-400.
2. Rouvray D.H. (Ed.) / Computational Chemical Graph Theory. New York, Nova Publ., 1989.
3. Connolly, M.L. Measurement of protein surface shape by solid angles, / J. of Molecular Graphics, v.4 n.1, p.3-6, March 1986

Морфологические методы анализа многофокусных изображений

А.А. Захарченко
(Москва)

Введение

В докладе описывается метод решения задачи реконструкции рельефа поверхности по набору изображений, полученных микроскопом с различными положениями фокуса. Метод инвариантен к условиям освещения, конструкции оптического прибора, формирующего изображение, и применим к широкому классу поверхностей. (Работа проделана при поддержке РФФИ, грант № 05-01-00615-а).

К настоящему времени существует множество методов реконструкции трехмерной поверхности по одному или нескольким двумерным изображениям. В приборах с малой глубиной фокуса (микроскоп) наиболее распространен анализ многофокусных изображений – изображений, снятых при различных расстояниях до объекта. Недостатком существующих методов является лишь качественное описание модели многофокусного изображения, на основании которой невозможно вычислить погрешность определения рельефа поверхности и, следовательно, построить измерительный прибор.

В данной статье предложен новый, морфологический подход к реконструкции трёхмерной поверхности по набору ее изображений, полученных оптическим микроскопом с разным положением фокуса. Использовался микроскоп с достаточно малой (по сравнению с другими оптическими приборами) глубиной фокуса (0.1 - 0.5 мкм).

Модель многофокусного изображения

Рассмотрим поверхность в трехмерном пространстве, заданную уравнением $z = z(x, y)$, (1)

и обозначим $f(x, y)$ яркость точки поверхности с координатами $(x, y, z(x, y))$. Будем считать, что среда, в которую помещена поверхность (1), не излучает и не рассеивает свет, поэтому пространственное распределение источников света можно записать в виде

$$I(x, y, z) = f(x, y)\delta(z - z(x, y)) = \begin{cases} f(x, y), & z = z(x, y) \\ 0, & z \neq z(x, y) \end{cases}. \quad (2)$$

Оптическая система, сфокусированная на плоскость $z = z_0$, формирует изображение поверхности на поле зрения X , являющемся ограниченным подмножеством плоскости R_2 . Изображение поверхности (1) с яркостью (2) запишется в виде

$$\xi(x_0, y_0, z_0) = \int a(x - x_0, y - y_0, z - z_0)I(x, y, z)dx dy dz,$$

где $a(.,.,.)$ - аппаратная функция микроскопа, $(x_0, y_0) \in X$, z_0 - положение фокуса микроскопа.

Как известно ([1]), аппаратная функция микроскопа представляет собой функцию рассеяния $H_z(u, v)$ дифракционно ограниченной оптической системы. Следуя рекомендациям работы [2], будем считать, что поверхность освещена светом, близким к некогерентному (Это достигается раскрытием апертурной диафрагмы освещения). Тогда функция рассеяния может быть приближена функцией, для которой $H_{z1}(u, v) \leq H_{z2}(u, v)$ при $|z1| \geq |z2|$, что выражает тот факт, что чем меньше расфокусировка, тем меньше подавляются высокие частоты в изображении поверхности. Можно показать, что такое приближение приведет к погрешности не более 1.7%.

Постановка задачи

По набору изображений $\xi(x_0, y_0, z_0)$, $(x_0, y_0) \in X$, с различными положениями фокуса $z_0 \in (z_{\min}, z_{\max})$, требуется восстановить поверхность $z = z(x, y)$ и яркость $f(x, y)$ в каждой точке $(x, y, z(x, y))$ этой поверхности, $(x, y) \in R_2$. Зафиксируем точку (x_0, y_0) плоскости изображения и рассмотрим набор фрагментов изображений $\xi(x_0, y_0, z_0)$, $z_0 \in (z_{\min}, z_{\max})$, в ε -окрестности $O_\varepsilon(x_0, y_0)$ выбранной точки (x_0, y_0) . Пусть $z(x_0, y_0)$ - внутренняя


точка интервала изменения фокуса (z_{\min}, z_{\max}) , тогда по мере изменения z от z_{\min} до z_{\max} сначала фрагмент изображения становится все более резким, затем, после прохождения точки $z(x_0, y_0)$, начинает снова размываться. Точка изменения характера поведения размытия является искомой высотой $z(x_0, y_0)$. Если изображение поверхности в рассматриваемой окрестности не является изображением константы, то мерой «расфокусировки» может служить интеграл от спектра мощности фрагмента изображения $\xi(x, y, z_0)$, $(x, y) \in O_\varepsilon(x_0, y_0)$, равный

$$S_{(x_0, y_0)}(z_0) = \int_{O_\varepsilon} (\xi(x, y, z_0) - \xi(z_0))^2, \quad \xi(z_0) = \int_{O_\varepsilon} \xi(x, y, z_0).$$

Это означает, например, что интеграл от квадрата отклонения яркости изображения фрагмента от константы в выбранной окрестности точки (x_0, y_0) максимален, когда участок изображения находится в фокусе.

Для оценки положения максимума функции $S_{(x_0, y_0)}(z_0)$, $z_0 \in (z_{\min}, z_{\max})$, воспользуемся морфологическим подходом [3] оценки высоты состоит в нахождении точки изменения поведения дисперсии. Рассмотрим функцию $S_{(x_0, y_0)}(\cdot)$, заданную на отрезке (z_{\min}, z_{\max}) , как искаженную шумом унимодальную функцию с положением максимума в точке $z_0 \in (z_{\min}, z_{\max})$. Множество таких функций образуют выпуклый замкнутый конус в пространстве всех функций, квадрат которых интегрируем на (z_{\min}, z_{\max}) . Этот конус назовем формой сигнала $S_{(x_0, y_0)}(\cdot)$ и обозначим $V_{(x_0, y_0)}(z_0)$. Оператор проецирования на это множество обозначим $P_{(x_0, y_0)}(z_0)$. Морфологический принцип оценки параметра z_0 состоит в нахождении множества унимодальных сигналов, к которому наиболее близок предъявленный сигнал

На рисунках ниже изображены реконструированные по 10 изображениям поверхности, покрытые золотом (высота рельефа 1.5 – 3 мкм).



Литература

1. Борн М. Вольф. Э. Основы оптики // Наука. М, 1970.
2. Введенский С. Захарченко А. Троицкий В. Измерения субмикронных размеров. Оптический микроскоп с некогерентным освещением. // «Электроника НТБ», 2005, 1, стр. 30
3. Пытьев Ю.П. Задачи морфологического анализа изображений. В сб. «Математические методы исследования природных ресурсов Земли из Космоса» // Наука. М, 1984

Особенности архитектуры системы распознавания объектных моделей OMRESYS (Object Model Recognition SYStem)

К.М. Квашин, М.И. Кумсков
(Москва)

Введение

Описана архитектура системы распознавания сцен на основе моделей, реализующей разработанную методiku [1][2][3]. Проектирование выполнено с использованием средства визуального моделирования Rational Rose, поддерживающем основные диаграммы UML [4]. В результате с помощью диаграмм классов выделены основные модули и объекты системы распознавания, а порядок их взаимодействия друг с другом определен на диаграммах взаимодействий и последовательностей.

Модули и основные объекты системы

В соответствии с объектно-ориентированным подходом [5] выделено несколько основных модулей и объектов системы распознавания: Интерфейс Пользователя, Блок Управления, Блок Анализа, Блок Данных и Объектная Модель.

Интерфейс Пользователя инкапсулирует графические компоненты, необходимые для взаимодействия с системой. В нем не содержится никакой логической функциональности системы: все запросы

пользователя передаются в Блок Управления для дальнейшей обработки.




Рис. 1. Диаграмма классов (UML): основные модули и объекты системы.

Каждый блок реализует интерфейс, через который с ним взаимодействуют другие подсистемы. Ниже приводится UML диаграмма (рис.2), на которой отражены не только отношения между Блоками и объектами системы распознавания, но и перечислены их сервисы, доступные для взаимодействия друг с другом:

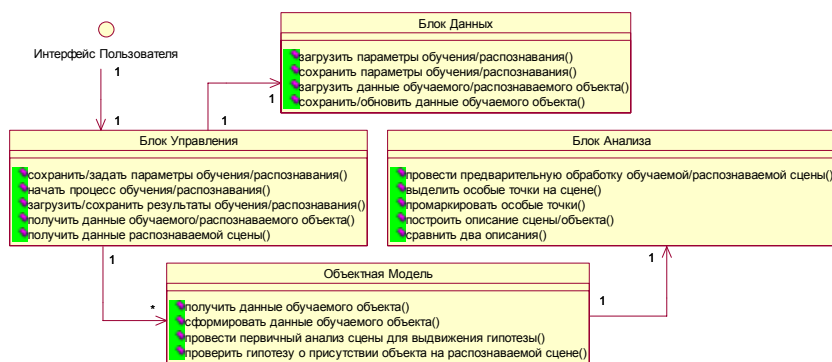


Рис. 2. Диаграмма классов, на которой указаны доступные сервисы Блоков.

Например, Блоку Управления для выполнения запросов на загрузку/сохранение данных требуется обратиться к Блоку Данных, имеющему соответствующие сервисы:

1. загрузить параметры обучения/распознавания;
2. сохранить параметры обучения/распознавания;
3. загрузить данные обучаемого/распознаваемого объекта;
4. сохранить/обновить данные обучаемого объекта.

На рис.3 приводится диаграмма последовательностей, иллюстрирующая последовательность обращения Блоков и объектов системы распознавания друг другу для построения описания объекта в процессе обучения системы.

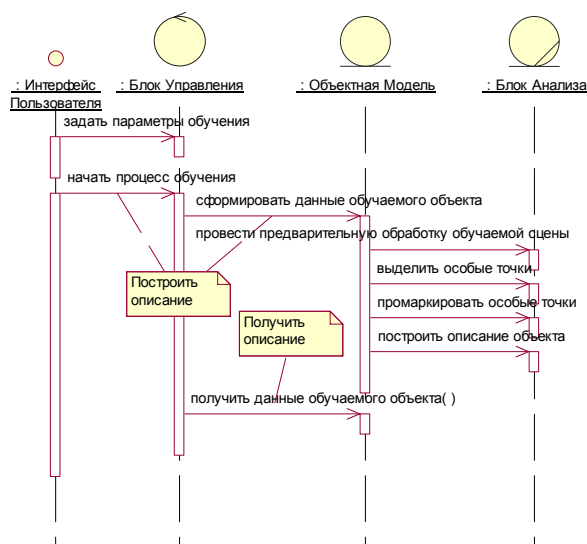


Рис. 3. Диаграмма последовательностей (UML): построение описания объекта.

В итоге с помощью приведенных и многих других диаграмм UML при проектировании архитектуры были учтены многие ее аспекты, а также критерии, которыми должна обладать уже реализованная система распознавания.

Результаты

С использованием UML проведено детальное проектирование архитектуры системы распознавания, реализующей методику распознавания сцен на основе моделей. В соответствии с объектно-ориентированным подходом, выделено несколько крупных подсистем, которые взаимодействуют друг с другом через доступные сервисы. Каждая из подсистем в свою очередь декомпозирована на компоненты, реализация которых выполнена на языке Java.

Литература

1. Квашнин К.Ю., Сергунин С.Ю., Кумсков М.И. Управление анализом сцены на основе объектной модели распознавания изображений // Труды международной научной конференции «Интеллектуализация обработки информации» (ИОИ-2004) 14-19 июня 2004. Алушта (Крым), 2004.
2. Кумсков М.И., Сергунин С.Ю., Квашнин К.М. Итерационное формирование описаний изображения, управляемое моделью объекта в задаче распознавания // Доклады 11-й Всероссийской конференции «Математические методы распознавания образов» (ММРО-11-2003) 23

- 29 ноября 2003. Пущино (Московская обл.), 2003. С. 343-346.
3. Квашнин К.М., Сергунин С.Ю., Кумсков М.И. Использование иерархии активных объектов при распознавании изображений сцен // Искусственный Интеллект. Донецк, 2004, № 2. С. 296-299.
 4. Ларман К. Применение UML и шаблонов проектирования. Введение в объектно-ориентированный анализ и проектирование. // Изд. дом Вильямс. Москва, 2001.
 5. Грэхем И. Объектно-ориентированные методы. Принципы и практика. // Изд. дом Вильямс. Москва, 2004.

**Особенности архитектуры системы распознавания
объектных моделей для выполнения на
многопроцессорных вычислительных комплексах**

К.М. Квашнин, М.И. Кумсков
(Москва)

Описан дизайн архитектуры системы, реализующей методику распознавания сцен данной предметной области [1][2][3], в нее были заложены решения, позволяющие системе распознавания использовать вычислительные возможности многопроцессорных платформ и, тем самым, значительно повысить ее производительность. Это является важным дополнительным свойством системы распознавания - способность обработки распознаваемых сцен в режиме реального времени.

Краткое описание архитектуры системы распознавания

На приведенной диаграмме UML [4] (рис.1) представлены основные Блоки и объекты системы распознавания: Интерфейс Пользователя, Блок Управления, Блок Анализа, Блок Данных и Объектная Модель. При этом показаны не только отношения между Блоками и объектами системы распознавания, но и перечислены основные сервисы каждого Блока, которыми может воспользоваться другой Блок или объект системы для выполнения своего запроса. Для запуска того или иного сервиса нужно вызвать соответствующий метод интерфейса, который реализует данный Блок, и передать параметры запроса, результаты которого возвращаются после его выполнения.

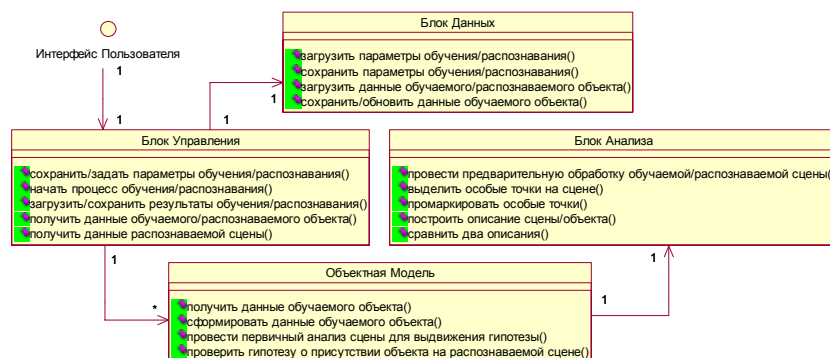


Рис. 1. Диаграмма классов, на которой приводятся доступные сервисы Блоков.

Выполнение на многопроцессорных комплексах

Одновременная (параллельная) обработка нескольких вычислительных процессов в рамках выполнения одного запроса – распространенное решение, позволяющее эффективно использовать возможности и ресурсы многопроцессорных вычислительных платформ. В этом случае важно, чтобы архитектура системы была сбалансирована, т.е. любое «узкое место» системы, в котором распараллеливание выполняющегося процесса невозможно, не должно содержать тяжелой функциональности, требующей больших вычислительных ресурсов для ее исполнения. Иначе, значительную часть времени система будет использовать только один процессор, в то время как остальные процессоры будут простаивать, что, в свою, очередь резко снизит эффективность применения многопроцессорных комплексов.

В случае приведенной архитектуры системы распознавания описанная проблема легко устраняется. Для этого функциональность, часто используемая в процессе обработки одного запроса пользователя и требующая больших вычислительных ресурсов, выделяется в качестве отдельного сервиса у соответствующего Блока или объекта системы. А при вызове данного сервиса запускается отдельный вычислительный процесс, в рамках которого сервис и выполняется. Для одновременного использования нескольких процессоров запускается нужное число процессов, в каждом из которых обрабатывается указанный сервис независимо от какого-либо другого сервиса.

Возможностью одновременного, параллельного и независимого выполнения среди указанных в предыдущем разделе основных сервисов Блоков и объектов системы распознавания обладают следующие сервисы:

1. провести первичный анализ сцены для выдвижения гипотезы;
2. проверить гипотезу о присутствии объекта на распознаваемой сцене;

3. все сервисы Блока Анализа.

Первый сервис Объектной Модели вызывается для проведения первичного анализа распознаваемой сцены, в результате которого может быть выдвинута гипотеза о присутствии на сцене объекта, за который отвечает текущая Объектная Модель. Для проверки выдвинутой гипотезы вызывается второй сервис данной Объектной Модели. Одновременная и параллельная работа этих сервисов осуществляется так: на этапе проведения первичного анализа сцены каждый раз «опрашивается» сразу несколько Объектных Моделей посредством вызовов первых из указанных сервисов. В процессе «опроса» всех Объектных Моделей формируется список из тех Объектных Моделей, которые выдвинули гипотезы, после чего производится параллельная проверка выдвинутых гипотез с помощью одновременного выполнения вторых сервисов соответствующих Объектных Моделей из списка.

Аналогичным способом сервисы Блока Анализа могут вызываться параллельно либо одной Объектной Моделью для, например, одновременного формирования нескольких описаний объекта, либо несколькими Объектными Моделями, когда, например, в ситуации одновременных проверок гипотез соответствующие Объектные Модели используют один и тот же сервис «сравнить два описания», но при этом для каждой из них выполняется «своя копия данного сервиса».

Результаты и выводы

В архитектуре системы, реализующей разработанную методику распознавания, заложена возможность обработки запросов пользователя на многопроцессорных платформах. При этом эффективность использования последних обусловлена сведением в системе к минимуму узких мест, в которых вычислительные процессы нельзя распараллелить, а также наличием сервисов у Блоков и объектов, многие из которых можно обрабатывать параллельно и независимо друг от друга.

Литература

1. Квашнин К.Ю., Сергунин С.Ю., Кумсков М.И. Управление анализом сцены на основе объектной модели распознавания изображений // Труды международной научной конференции «Интеллектуализация обработки информации» (ИОИ-2004) 14-19 июня 2004. Алушта (Крым), 2004.
2. Кумсков М.И., Сергунин С.Ю., Квашнин К.М. Итерационное формирование описаний изображения, управляемое моделью объекта в задаче распознавания // Доклады 11-й Всероссийской конференции «Математические методы распознавания образов» (ММРО-11-2003) 23 - 29 ноября 2003. Пущино (Московская обл.), 2003. С. 343-346.
3. Квашнин К.М., Сергунин С.Ю., Кумсков М.И. Использование иерархии активных объектов при распознавании изображений сцен //

Искусственный Интеллект. Донецк, 2004, № 2. С. 296-299.

4. Ларман К. Применение UML и шаблонов проектирования. Введение в объектно-ориентированный анализ и проектирование. // Изд. дом Вильямс. Москва, 2001.

Удаление зашумленного фона с изображения ионограммы наклонного зондирования ионосферы

А.А. Колчев, А.О. Щирый

(Йошкар-Ола)

Наклонное зондирование ионосферы позволяет существенно повысить надежность КВ-связи. Результат работы ионозонда представляется в виде ионограммы, являющейся растровым изображением зависимости времени группового запаздывания (вертикальная ось) и амплитуды сигнала (изображена цветом или яркостью) от рабочей частоты (горизонтальная ось). Кроме следов («треков») различных мод распространения полезного сигнала (представляющих обычно протяженные по горизонтали кривые) на ионограмме присутствуют различные виды помех, которые в данной работе мы назовем зашумленным фоном (рис.1). Удаление этого фона является необходимым первоначальным этапом автоматической обработки ионограмм (с целью оценить параметры полезного сигнала).




Рис. 1. Пример изображения ионограммы

В теории обработки результатов измерений [1] известны методы обнаружения резко выделяющихся значений выборки (их обнаруживают для исключения из рассмотрения). Один из этих методов, позволяющий принять решение на основе оценок числовых характеристик выборки, не прибегая к выбору закона распределения, заключается в следующем.

Если для величины a_k выполняется условие

$$|a_k - \bar{a}| \leq \sigma \cdot (1,55 + 0,8\sqrt{E + 2} \cdot \lg(N/10)), \text{ где } \bar{a} = \frac{1}{N} \sum_{i=1}^N a_i,$$

σ и E – соответственно СКО и эксцесс выборки a размером N , то нет оснований считать это значение значительно отличающимся от среднего. Очевидно, что для решаемой задачи, метод применялся «наоборот», т.е. резко выделяющиеся отсчеты выборки считались полезным сигналом, оставшиеся занулялись. Обработка производилась блоками соответствующими одному спектру сигнала, т.е. одной вертикальной линии изображения ионограммы.




Рис. 2. Пример удаления зашумленного фона ионограммы

Эффективность описанной методики иллюстрирует рис.2, где приведен пример удаления зашумленного фона с изображения (растрового образа) ионограммы.

Предложенная методика обладает рядом преимуществ перед известными ранее методиками очистки ионограмм от помех [2, 3], важнейшие из которых: существенно меньшая вычислительная трудоемкость (примерно на порядок), позволяющая производить выделение полезного сигнала в реальном времени в течение сеанса зондирования; отсутствие параметров алгоритма, задаваемых оператором в зависимости от протяженности трассы, порядка мод, зашумленности и т.п. [2, 3], что позволяет полностью автоматизировать процесс обработки.

Литература

1. Новицкий П.В., Зограф И.А. Оценка погрешностей результатов измерений. – Л.: Энергоатомиздат, 1991. – 304с.
2. Егошин А.Б., Иванов В.А., Колчев А.А., Шумаев В.В. Методы

обработки и интерпретации ионограмм наклонного ЛЧМ-зондирования // Распространение радиоволн: Тез. докл. XIX Всерос. науч. конф. – Казань, 1999. – с.118-119.

3. Егошин А.Б. Автоматизированная система адаптивной обработки сигналов со сверхбольшой базой для радиозондирования ионосферных радиолиний: Дис. канд. техн. наук / МарГТУ. – Йошкар-Ола, 2003.

Сжатие полутоновых изображений рукописных документов на основе кодирования по изолиниям яркости

С.В. Котик, А.И. Майсурадзе, Л.М. Местецкий

(Москва)

Введение

В последние годы большое число исторических и архивных документов переводится в электронную форму для того, чтобы обеспечить их сохранность и удобство работы с ними. Сжатие изображений, полученных в результате сканирования документов, является очень актуальной задачей, ведь объем электронных архивов изображений достигает подчас сотен, а то и тысяч гигабайт. Обычно документы переводятся в форму бинарного изображения (черный текст на белом фоне), занимающего существенно меньший объем памяти, чем полутоновые или цветные изображения. Однако, несмотря на наличие достаточно развитых алгоритмов бинаризации (см., например, [4]), при таком преобразовании документы часто очень сильно искажаются, даже становятся нечитаемыми.

Предлагаемый нами подход состоит в построении для исходного полутонового документа нескольких бинарных изображений, обеспечивающих приемлемое качество визуализации сохраняемого документа, и последующего общего контурного кодирования всей совокупности отдельных бинарных изображений, позволяющего добиться высокой степени сжатия. Отличительной особенностью подхода является то, что он обоснованно допускает потери в сохраняемом изображении, позволяя оценить их влияние на степень сжатия. Работа выполнена при поддержке РФФИ (грант 05-01-00542).

Подход

Подход основан на кодировании изолиний яркости изображения. Исходное изображение бинаризуется с различными порогами (берется 3-7 порогов), затем совокупность получившихся черно-белых изображений сжимается на основе контурного кодирования [2]. При восстановлении осуществляется последовательная отрисовка бинарных изображений одно поверх другого с уровнями яркости, рассчитанными по соответствующим областям исходного изображения. Сначала отображается фон, затем самый светлый слой (с наиболее светлым пороговым значением при

бинаризации), затем следующий по яркости и т.д. Последним выводится самый темный слой. Возможны и более тонкие способы визуализации, например, гораздо более качественным восстановленное изображение будет, если интерполировать цвета при переходе от одной изолинии к другой. Пример исходного и восстановленного по бинарным сечениям изображения представлен на рис.1. Качество восстанавливаемого изображения можно варьировать с помощью выбора количества «срезов» (количества получающихся бинарных изображений) и с помощью выбора собственно значений порогов. Соответственно, изменяется и объем получающегося сжатого архива.

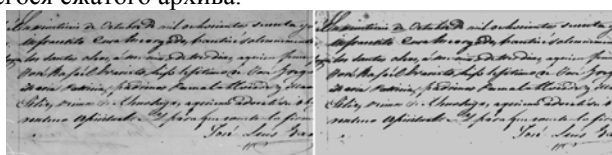


Рис. 1. Исходное и восстановленное (3 порога) изображения.

Контурное кодирование

Сжатие получившихся в результате бинаризации с разными порогами черно-белых изображений основано на методе контурного кодирования [2]. Специфика изображений текста в том, что линия границы, отделяющая черные точки изображения (текст) от белых точек (фон) может быть аппроксимирована многоугольниками с очень короткими сторонами.

Для аппроксимации дискретного бинарного изображения используются многоугольные фигуры минимального периметра. Для построения аппроксимирующей полигональной области минимального периметра разработан метод, включающий три этапа: поиск, прослеживание и вытягивание границы [3].

Идея дальнейшего кодирования контуров состоит в следующем. Каждый многоугольник с $n+1$ вершинами (V_0, V_1, \dots, V_n) может быть задан начальной вершиной V_0 и последовательностью векторов $\overline{V_0V_1}, \overline{V_1V_2}, \dots, \overline{V_{n-1}V_n}$, называемых офсетом. Кодирование контура состоит в запоминании координат начальной вершины и офсетов, задаваемых парами координат. Офсеты имеют явно выраженную неравномерность распределения, что позволяет эффективно применить для запоминания последовательности офсетов методы кодирования с минимальной избыточностью, которые предназначены для сжатия кортежей символов из заданного алфавита.

В нашем случае алфавитом является набор всевозможных офсетов – пар целых чисел (x, y) , то есть одна такая пара – это символ. Тогда контуры (многоугольники) представляются в виде кортежей символов алфавита офсетов. В экспериментах использовался алгоритм PPM (Prediction by Partial Matching) [1,5].

Вычислительные эксперименты

При сравнении с другими алгоритмами сжатия полутоновых изображений за основу брались результаты, показанные кодировщиком DjVu, лучшим в данном классе[6]. В таблице 1 показаны результаты работы с двумя изображениями различной яркости и размера (рис. 2). Как показывают результаты экспериментов, предлагаемый метод кодирования по изолиниям яркости превосходит DjVu даже при достаточно высоком качестве сжатого



Рис.2. Pic1 (слева) и Pic2 .

изображения (5÷7 пороговых значений), причем чем больше размер исходного изображения, тем больше выигрыш по сравнению с DjVu.

Таблица 1. Сравнение с DjVu.

Имя	Размер	Объем	Кол-во порогов	Объем архива	Объем DjVu
Pic1	1450x2275	9669 kb	3	89 kb	214 kb
Pic1	1450x2275	9669 kb	5	153 kb	214 kb
Pic1	1450x2275	9669 kb	7	211 kb	214 kb
Pic2	360x420	494 kb	3	16 kb	27kb
Pic2	360x420	494 kb	5	24 kb	27kb
Pic2	360x420	494 kb	7	33 kb	27kb

Заключение

Предложенный подход к сжатию полутоновых изображений является альтернативой существующим на сегодняшний день методам. Результаты экспериментов показывают, что по степени сжатия он превосходит все распространенные сейчас в этой нише алгоритмы. Подход позволяет на каждом этапе работы в широких пределах варьировать свои параметры для достижения желаемого соотношения «качество-объем», а также управлять временными затратами на сжатие и распаковку.

Литература

1. Д. Ватолин, А. Ратушняк, М. Смирнов, В. Юкин. Методы сжатия данных. Устройство архиваторов, сжатие изображений и видео // Издательство «ДИАЛОГ-МИФИ». Москва, 2002.
2. С. В. Котик, Л. М. Местецкий. Сжатие бинарных изображений текста на основе контурного кодирования // Доклады 7 Международной конференции PRIA -7-2004. Санкт-Петербург, 2004.

3. М. Местецкий. Векторизация бинарных растровых изображений на основе аппроксимации.// Доклады X Всероссийской конференции «Математические методы распознавания» (ММРО-10). Москва, 2001
4. Graham Leedham, Saket Varma, Anish Patankar, Venu Govindaraju. Separating text and background in degraded document images – a comparison of global thresholding techniques for multi-stage thresholding.// Proceedings of 8th International workshop on Frontiers in handwriting recognition, Ontario, Canada, 2002.
5. <http://www.compression.ru> Все о сжатии. Сайт о сжатии информации.
6. <http://www.lizardtech.com> Сайт компании - разработчика DjVu.

Система кредитного скоринга на основе логических алгоритмов классификации

Д.А. Кочедыков, А.А. Ивахненко, К.В. Воронцов
(Москва)

Задача кредитного скоринга

Задача кредитного скоринга возникает в банках и других кредитных организациях при принятии решений о выдаче кредитов. Задача заключается в том, чтобы на основе некоторой информации о заявителе обоснованно принять решение — стоит ли ему выдавать кредит, и если да, то на каких условиях. Если речь идёт о физических лицах, то исходной информацией для классификации заёмщиков на «хороших» и «плохих» является заполняемая ими анкета, информация о прошлых кредитах заёмщика (кредитная история), в некоторых случаях — информация о движении средств на счетах заёмщика. В анкете указывается сумма и назначение кредита, возраст, пол, социальное положение, образование, профессия, и т. д. Сотрудники банка могут вносить дополнительные сведения, например, психологический портрет заёмщика или результаты проверки, проведённой службой безопасности банка. В итоге формируется описание заёмщика, содержащее от 20 до 200 признаков, в зависимости от используемой банком методики оценки кредитоспособности.

Перечислим некоторые специфические особенности данной прикладной задачи, которые накладывают существенные ограничения на выбор модели алгоритма классификации и способы её настройки.

1. Анкетные данные, как правило, являются неполными и разнородными. Кроме того, они характеризуются высоким уровнем шума, так как невозвраты кредитов чаще всего обусловлены случайными факторами. В некоторых случаях построить классификатор, допускающий менее 25% ошибок, не представляется возможным. Отчасти это компенсируется тем, что ошибки I и II рода неравноценны: по экспертным оценкам пропуск «плохого» заёмщика обходится банку в 3–10 раз дороже, чем потеря «хорошего» клиента.

2. Наряду с классификацией банк решает задачу определения риска, который несет в себе выдача запрошенного кредита в каждом конкретном случае и принятие решения о приемлемости такого риска для кредитного портфеля. При этом банк старается минимизировать риск и максимизировать прибыль путём варьирования условий выдаваемого кредита — ставки, суммы, срока, и т. д. Для решения этих задач алгоритм должен выдавать не только саму классификацию, но и оценку вероятности того, что данный заёмщик принадлежит классу «плохих». Кроме того, должна быть возможна более тонкая классификация рисков, чем «плохой»/«хороший»: кредит может возвращаться не полностью, либо с задержками (что влечёт операционные расходы), либо досрочно (что влечёт потерю части прибыли).

3. Одно из самых существенных ограничений состоит в том, что алгоритм классификации заёмщиков должен быть простым, понятным кредитному эксперту и должен допускать запись на естественном языке в терминах предметной области.

4. В настоящее время многие российские банки только приступают к кредитной деятельности и ещё не накопили значительного числа кредитных историй. Поэтому алгоритмы приходится настраивать по малому числу прецедентов. Используемые в западных банках на протяжении 40 лет статистические методы не могут уверенно работать на столь малых обучающих выборках. В частности, к этим методам относится широко применяемая логистическая регрессия, с помощью которой строят так называемые «скоринговые карты».

Логические алгоритмы классификации

Сформулированным выше требованиям удовлетворяют логические алгоритмы классификации, в частности, решающие списки, решающие деревья и алгоритмы типа «Кора», основанные на взвешенном голосовании конъюнкций. Все они строятся в виде композиции простых логических условий и хорошо интерпретируются. Вместе с тем, применение в области кредитного скоринга требует существенной доработки классических методов синтеза логических классификаторов — при любых условиях они должны оставаться интерпретируемыми, и их настройка должна занимать приемлемое время. При этом приходится искать компромисс между точностью настройки на обучающих данных и сложностью алгоритмов.

В данной работе рассматриваются алгоритмы синтеза классификаторов, основанные на поиске логических закономерностей. *Закономерность* — это предикат $\varphi_c : X \rightarrow \{0,1\}$, определённый на множестве объектов X . Если $\varphi_c(x) = 1$, то говорят, что закономерность φ_c относит объект x к классу c . Будем рассматривать закономерности, имеющие вид конъюнкции простых однопризнаковых условий

$$\varphi_c(x) = \beta_1(x) \wedge \dots \wedge \beta_k(x),$$

где термы $\beta_i(x)$ имеют вид $[x_j < a]$, $[x_j > a]$, $[x_j = a]$ или $[a < x_j < b]$, (x_1, \dots, x_n) — признаковое описание объекта x . Синтез закономерности заключается в оптимизации числа термов k , опорного множества признаков, образующих термы, и параметров a, b в каждом терме. Оптимизация производится по критерию информативности на основе *точного теста Фишера* [1]. Это позволяет находить достаточно надёжные закономерности в условиях зашумлённых данных малого объёма. Синтез информативных конъюнкций производится методом усечённого поиска в ширину, аналогичным алгоритму ТЭМП [2] или многорядному итерационному алгоритму МГУА. При реализации алгоритма было введено несколько десятков различных эвристик, нацеленных на повышение качества, интерпретируемости и разнообразия синтезируемых закономерностей.

Получаемые закономерности $\varphi_{c_1}^1(x), \dots, \varphi_{c_T}^T(x)$ объединяются в алгоритм классификации одним из двух способов.

1. *Решающий список* закономерностей (decision list, DL) или комитет старшинства. При классификации объекта x закономерности проверяются последовательно для всех $t = 1, \dots, T$, пока для некоторого t не выполнится условие $\varphi_{c_t}^t(x) = 1$. Тогда объект x относится к классу c_t . На практике оказалось, что решающие списки хорошо интерпретируются экспертами только в том случае, когда для каждого класса c строится отдельный список $\varphi_c^1(x), \dots, \varphi_c^T(x)$ и закономерности разных классов не перемешиваются.

2. *Взвешенное голосование* закономерностей (weighted voting, WV) или комитет взвешенного большинства. В этом алгоритме объект x относится к тому классу c , для которого максимальна доля закономерностей $\Gamma_c(x)$, относящих данный объект к данному классу:

$$\Gamma_c(x) = \frac{1}{T_c} \sum_{t=1}^{T_c} w_t \varphi_c^t(x).$$

Для настройки весов закономерностей w_t используется вариант алгоритма бустинга [3]. Преимущества бустинга в том, что он позволяет вычислять веса по явным формулам и последовательно строить закономерности таким образом, чтобы каждая следующая существенно отличалась от предыдущих, что способствует улучшению интерпретируемости. Кроме того, бустинг позволяет эффективно выделять из обучающей выборки шумовые объекты.

Экспериментальное сравнение качества алгоритмов

Был проведен эксперимент по сравнению качества работы предложенных алгоритмов DL и WV с эталонными алгоритмами на 6 наборах реальных данных из репозитория UCI [4], причём german, srx и australian — задачи о выдаче кредитов по анкетным данным. В таблице 1 приведены доли ошибок на скользящем контроле в процентах от длины обучающей выборки. Алгоритмы DL и WV показали качество классификации, сравнимое со стандартными алгоритмами. Отметим, что оба алгоритма существенно превосходят остальные на выборке малого размера (hepatitis).

Программный комплекс ScoringAce®

На основе разработанных алгоритмов классификации создан программный комплекс ScoringAce для поиска логических закономерностей в данных, автоматического и полуавтоматического построения хорошо интерпретируемых алгоритмов классификации и автоматизации принятия кредитных решений. Программный комплекс внедрен в одном из крупных российских банков и в настоящее время используется при массовом кредитовании физических лиц. Архитектура программного комплекса складывается из следующих компонент.

Решающий сервер предназначен для обработки поступающих кредитных заявок и принятия кредитных решений в режиме онлайн. База данных сервера накапливает кредитные истории, хранит все действующие в настоящее время и действовавшие в прошлом логические классификаторы (скоринговые модели), а также протоколирует всю информацию, проходящую через сервер.

АРМ аналитика рисков используется для статистического анализа данных, поиска закономерностей, построения логических классификаторов, оценивания риска отдельных кредитов и текущего кредитного портфеля в целом, построения аналитических отчетов.

АРМ кредитного аналитика служит для online-верификации решений, принимаемых Решающим сервером по поступающим заявкам на выдачу кредитов. Используется, в частности, при выходе на новые рынки для оперативного контроля и корректировки принимаемых решений.

АРМ аудита применяется для отслеживания процессов кредитования и построения статистических отчетов по работе Решающего сервера.

АРМ подписания скоринг-моделей предназначено для обновления списка текущих скоринговых моделей на Решающем сервере.

Задача	RIPPER		C4.5		C5.0	SLIP ER	DL	VW
	-opt	+opt	Trees	Rules				
german	28.6	28.7	27.5	27.0	28.3	27.2	28.2	27.9
hepatits	20.7	23.2	18.8	18.8	20.1	17.4	7.7	8.4
crx	15.5	15.2	14.2	15.5	14.0	15.7	13.9	14.2
liver	32.7	31.3	37.7	37.5	31.9	32.2	30.6	28.4
horse- colic	17.0	16.3	16.3	16.0	15.3	15.0	21.7	16.7
australian	14.7	—	15.2	—	14.6	—	15.1	12.8

Таб.1 Сравнение качества логических алгоритмов классификации. Процент ошибок на тестовых данных при 10-кратном скользящем контроле (10-fold cross-validation).

Литература

1. Martin J. K. An exact probability metric for decision tree splitting and stopping // Machine Learning. — 1997. — Vol. 28, no. 2-3. — Pp. 257–291.
2. Лбов Г. С. Методы обработки разнотипных экспериментальных данных. — Новосибирск: Наука, 1981.
3. Cohen W. W., Singer Y. A simple, fast and effective rule learner // Proc. of the 16 National Conference on Artificial Intelligence. — 1999. — P. 335.
4. Blake C., Merz C. UCI repository of machine learning databases: Tech. rep.: University of California, Irvine, CA, 1998.

Об одном алгоритме динамического обучения принятию решений в дискретных временных рядах

А.Е. Кругов
(Москва)

В докладе рассматривается задача принятия решений по временному ряду, каждая точка которого описывается набором дискретных признаков. Предлагается алгоритм отбора информативных признаков, который можно также рассматривать как алгоритм поиска логических закономерностей в дискретных временных рядах. Критерием настройки является монотонность возрастания заданного функционала полезности. Алгоритм опробован на реальных данных в задаче формирования инвестиционного портфеля.

Постановка задачи

Рассматривается следующая задача принятия решений на временных рядах. Имеется временной ряд событий $p(0), p(1), \dots, p(T)$ со значениями из заданного множества возможных событий P . В каждый момент времени t происходит событие $p(t)$ и становится известен вектор N дискретных признаков $x(t) = [x_1(t), x_2(t), \dots, x_N(t)]$, характеризующий данное событие. На основе этой информации принимается решение

$g(x(t))$ из конечного множества допустимых решений G . Полезность решения определяется только в следующий момент времени, когда становится известно событие $p(t+1)$, и задаётся функцией $\Phi(p, g)$. Предполагается также, что среди множества допустимых решений G есть нулевое решение e такое, что $\Phi(p, e) = 0$ для любого $p \in P$. Требуется построить алгоритм принятия решений, реализующий функцию $g(x)$, и обеспечивающий как можно более монотонный рост суммарной полезности на заданном интервале времени $[0, T]$:

$$\Phi[0, T] = \sum_{t=0}^{T-1} \Phi(p(t+1), g(x(t))).$$

В том случае, когда параметры алгоритма g настраиваются по предыстории ряда $\{p(\tau), x(\tau)\}_{\tau=0}^t$ перед каждым принятием решения, будем говорить о задаче *динамического обучения принятию решений*. В данной работе предлагается алгоритм обучения, основанный на выявлении закономерных связей между описаниями ситуаций и полезностью допустимых решений.

Оценивание информативности наборов признаков

На практике признаки x_1, \dots, x_N , как правило, имеют различную информативность. Возникает задача отбора оптимального подмножества признаков $\{i_1, \dots, i_n\} \subseteq \{1, \dots, N\}$, только от которых и будет зависеть функция $g(x)$. Поскольку $g(x_{i_1}, \dots, x_{i_n})$ является дискретной функцией дискретных аргументов, будем задавать её таблицей, в которой для каждого вектора аргументов $\bar{b} = (b_1, \dots, b_n)$ непосредственно записано значение функции $g(\bar{b})$. Если некоторый вектор отсутствует в таблице значений, по умолчанию предполагается, что ему соответствует нулевое решение e .

Рассмотрим произвольный вектор аргументов $\bar{b} = (b_1, \dots, b_n)$. Пусть $\tau_1 < \tau_2 < \dots < \tau_m$ — моменты времени из отрезка $[0, t]$, для которых выполняются условия $x_{i_1}(\tau) = b_1, \dots, x_{i_n}(\tau) = b_n$. Введём функцию суммарной полезности, приносимой вектором \bar{b} с течением времени τ_j :

$$P(\bar{b}, i) = \sum_{j=0}^i \Phi(p(\tau_j), g(b_1, \dots, b_n)).$$

Введём также следующие характеристики функции $P(\bar{b}, i)$:

- минимальное значение полезности: $P_1(\vec{b}) = \min_{1 \leq i \leq m} P(\vec{b}, i)$;
- максимальное значение полезности: $P_2(\vec{b}) = \max_{1 \leq i \leq m} P(\vec{b}, i)$;
- максимальное падение полезности, характеризующее непостоянство роста полезности: $D(\vec{b}) = \max_{i, j: \tau_j < \tau_i} (P(\vec{b}, \tau_j) - P(\vec{b}, \tau_i))$.

На их основе построим величину, характеризующую степень немонотонности роста $P(\vec{b}, t)$ во времени: $d(\vec{b}) = D(\vec{b}) / (P_2(\vec{b}) - P_1(\vec{b}))$. Теперь определим функционал качества, характеризующий функцию g , как среднее значение d по всем значениям \vec{b} , для которых эта величина определена:

$$J(g) = \sum_{\vec{b}: P_2(\vec{b}) > P_1(\vec{b})} d(\vec{b}) / |\{\vec{b} \mid P_2(\vec{b}) > P_1(\vec{b})\}|.$$

Алгоритм

Для построения функции g предлагается использоваться «жадный» алгоритм постепенного наращивания числа аргументов в функции g .

В качестве начального приближения выбирается $g_0 = const$ из условия максимизации полезности на обучающем интервале времени.

К уже построенной на предыдущих шагах функции по очереди добавляются все возможные новые аргументы. Таблицы значений новых функций строятся исходя из требования максимизации полезности на обучающем интервале времени. Среди этих функций выбирается функция с минимальным значением функционала $J(g)$.

Остановка алгоритма происходит по двум условиям:

— Число аргументов функции достигает определённого порогового количества, которое является параметром алгоритма.

— Скорость уменьшения функционала, задаваемая отношением $J(g_{n-1}) / J(g_n)$, становится меньше заданного порога, который также является параметром алгоритма.

Результаты

Предложенный алгоритм был апробирован на реальных данных в задаче формирования инвестиционного портфеля [1]. В данном случае ряду событий $p(t)$ соответствовали цены выбранного финансового инструмента (акции). В качестве информационных рядов $x(t)$ использовались бинарные ряды, описывающие поведение курса акции в ближайшем прошлом. Множество допустимых решений состояло из трёх элементов: покупка 1 акции, продажа 1 акции, и нулевое решение e —

«ничего не делать». Функция полезности измеряла текущую прибыль от торговых операций. В экспериментах предложенный алгоритм показал прибыльность, сопоставимую со стандартными техническими индикаторами рынка [2], или превосходящую их.

Фактически, предложенный алгоритм поиска логических закономерностей является обобщением знаменитых «японских подсвечников» — эмпирических правил биржевой игры, составленных и проверенных вручную многими поколениями трейдеров. Предложенный алгоритм способен отыскивать такого рода правила автоматически, на основе анализа исходных данных. При этом появляется возможность оптимизировать индивидуальные наборы правил для различных рынков, и даже для отдельных финансовых инструментов.

Литература

1. Романов М.Ю., Ументаев С.А., Кругов А.Е., Воронцов К.В. Алгоритмы динамического обучения принятию решений в задаче формирования инвестиционного портфеля // В настоящем сборнике. 2005.
2. Колби Р., Мейерс Т. Энциклопедия технических индикаторов рынка. — Издательский дом «Альпина», 1998.

Логико-статистическое прогнозирование биологического возраста по данным биоактивных точек

А.В. Кузнецова, В.Б. Мамаев, О.В. Сенько

(Москва)

Введение

Работа посвящается решению задачи оценки биологического возраста (БВ) по состоянию биоактивных точек, определяемых по методу Фолля. Для оценки БВ в работе использовались методы распознавания образов в рамках логико-статистического подхода.

Определение биологического возраста является ключевой проблемой геронтологии. Ее решение позволяет определить степень жизнеспособности организма, связанную с возрастными изменениями [1]. В настоящее время унифицированной методики определения БВ еще не выработано. Для решения этой задачи используются в частности методы математического моделирования по эмпирическим данным, использующие коррелирующие с возрастом морфологические, физиологические, биохимические и психометрические тесты. При этом критерием адекватности моделей БВ является их соотношение с календарным временем (КВ). Так ранее были построены модели БВ, основанные на одномерной и множественной линейной регрессии между КВ и маркерами старения [1]. Однако данные подходы имеют не достаточно высокую эффективность. Недостаточность использования для

оценок БВ только линейного моделирования связана с отсутствием показателей в одинаковой степени, отражающих возрастные изменения в течение всей жизни. Кроме того многие из используемых физиологических тестов сложны для выполнения. Все эти обстоятельства явились мотивацией использования для оценок БВ методов электроakupунктурной диагностики и распознавания образов.

Материалы и методы

Основными достоинствами метода электроakupунктуры являются неинвазивный характер метода, простота оборудования, универсальность подхода к различным системам организма, возможность непосредственного введения данных в компьютер. Обследование проводили, измеряя электрическую проводимость в акупунктурных точках по методу Р. Фолля. В основе электроakupунктурной диагностики лежит единая система оценки результатов измерений электрических параметров для всех органов, тканей и взаимосвязанных с ними биологически активных точек (БАТ). С помощью специальной градуировочной шкалы оценивается характер нарушения функции различных органов и тканевых систем. Для анализа данных использовались метод оптимальных разбиений и метод распознавания Статистически Взвешенные Синдромы, которые ранее также применяли для анализа акупунктурных данных при анализе стрессовых состояний [2].

Результаты исследования методом статистически-взвешенных синдромов и методом оптимальных разбиений

В ходе работы было обследовано 585 человек, среди которых было 415 женщин и 170 мужчин. Обследуемые были разделены на группы по полу. В задаче определения биологического возраста для женщин массив данных несколько раз был разделен на 2 группы. Граница деления сдвигалась через 5 лет, начиная с 20 лет, заканчивая 60 годами. Для каждого деления проводилась процедура распознавания с выделением с помощью пошаговой процедуры набора наиболее информативных показателей. Результат распознавания представлен в таблице.

Таблица. Результаты распознавания для женщин при изменении возрастной границы разбиения массива данных.

Гран возр.	Правиль-но	Ошибки	Отказ	Признаки*
20	261(0,8)	41	113	10, 12, 18, 42, 15, 43
25	276(0,86)	45	94	10, 12, 26, 42, 19, 43, 41, 18, 34, 22
30	265 (0,81)	61	89	6, 16, 12, 9, 19, 18, 10, 42, 38, 30
35	260 (0,74)	92	63	43, 16, 28, 38, 21, 40, 22, 12, 9, 31, 10, 27, 18
40	271 (0,76)	87	57	8, 27, 16, 12, 40, 15, 30, 38, 9, 21, 42
45	269 (0,77)	79	67	12, 13, 40, 28, 21, 16, 8, 14, 6, 38, 35, 24, 4, 42
50	276 (0,82)	62	77	29, 31, 13, 35, 4, 33, 15, 8, 21, 20, 40, 39, 43, 42
55	289 (0,86)	49	77	28, 33, 13, 31, 19, 39, 8, 20, 24, 40, 22, 18, 6
60	299 (0,93)	21	95	33, 31, 29, 19, 28, 24, 36, 37, 26, 13, 34, 8, 39, 14, 17, 42, 9, 41
65	308(0,98)	7	100	40, 15, 17, 28, 31, 25, 23, 34, 32, 12, 11

1 класс - обследуемые с возрастом ниже границы, 2 группа - соответственно - с возрастом выше границы. * - Обозначения признаков, соответственно справа и слева: 4-5 - лимфоидная система, 6-7 - дыхательная система, 8-9 - толстый кишечник, 10-11 - нервная система, 12-13 - сосуды, 14-15 - иммунная система-1, 16-17 - иммунная система-2, 18-19- иммунная система-3, 20-21- сердце, 22-23- тонкий кишечник, 24-25- поджелудочная железа, 26-27- печень, 28-29 - суставы, 30-31- желудок, 32-33- соединительная ткань, 34-35- кожа, 36-37- жировая ткань, 38-39- желчный пузырь, 40-41- почки, 42-43 - мочеполовая система.

При статистической верификации признаков, проведенной с помощью перестановочного теста в рамках метода оптимальных разбиений, все признаки оказались достоверно значимы с точки зрения разделения соответствующих двух групп. При подведении итогов распознавания обращает на себя внимание тот факт, что некоторые показатели встречаются гораздо чаще остальных. Наиболее информативными оказались показатели меридиана перикарда, мочевого пузыря, почек, толстого кишечника, тройного обогревателя, суставной дегенерации и

желудка.

В результате проведенной работы возникает перспектива создания нового метода определения биологического возраста человека, включающего измерение наиболее важных показателей организма мужчин и женщин.

Выводы

1. С помощью логико-статистических методов распознавания образов созданы алгоритмы оценки принадлежности испытуемого к возрастной категории ниже или выше границы для всех возрастов с шагом 5 лет как для мужчин, так и для женщин.
2. Выявлены наборы информативных показателей состояния меридианов по Фолю для распознавания при оценке биологического возраста с делением по всем возрастам и полам.
3. Предлагаемый метод определения биологического возраста может оказаться полезным при оценке состояния здоровья (биологического возраста) и может быть использован в амбулаторных условиях, при эпидемиологических обследованиях больших контингентов и т.д.

Работа была выполнена при поддержке программы президиума РАН «Фундаментальные науки – медицине» и РФФИ (гранты 05-07-9033, 05-01—00332)

Литература

1. Войтенко В.П., Полюхов А.М., Барбарук Л.Г., Колодченко В.П., Ходзинский А.Н. Биологический возраст, как ключевая проблема геронтологии. // Институт геронтологии АМН СССР, Киев.
2. Kuznetsova A.V., Sen'ko O.V., Matchak G.N., Vakhotsky V.V., Zabolina T.N., Korotkova O.V. The Prognosis of Survivance in Solid Tumor Patients Based on Optimal Partitions of Immunological Parameters Ranges // J Theor Med. – 2000. - V.2. - P.317-327.
3. Sen'ko O.V., Kuznetsova A.V., Strelnikov A.N., Mamaev V.B. The Use of Pattern Recognition in Investigation of Electro Puncture Diagnostics for Evaluating of Nervous and Psychic States. 7th International Conference on Pattern Recognition and Image Analysis: New Information Technologies. PRIA-7-2004. St. Petersburg, 2004, p.886-889.

**Спектральное разложение данных магнитной
энцефалографии и вывод аналитических соотношений
между коэффициентами разложения при типовых
операциях с сигналами**

Л.И. Куликова, С.А. Махортых

(Пушино)

Магнитная энцефалография (МЭГ) – интенсивно развивающаяся область экспериментального изучения высшей нервной деятельности человека, функциональных областей мозга и диагностики различных патологий. Это обусловлено возможностью неинвазивного получения данных о процессах, происходящих как в коре головного мозга, так и в глубоких его отделах. Чрезвычайная слабость как спонтанных, так и вызванных магнитных полей, возбуждаемых токовыми источниками в мозге, накладывает повышенные требования к используемой измерительной аппаратуре и методам обработки полученных данных. Несмотря на возникающие технические трудности и высокую стоимость необходимого экспериментального оборудования, использование данного подхода как дополнения или альтернативы электрической энцефалографии оправдано следующим обстоятельством. 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.

Прямая задача магнитной энцефалографии состоит в нахождении магнитного поля по известным источникам [4]. 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 [3]:

$$B(\mathbf{r}) = \frac{\mu_0}{4\pi F^2} ((F(\mathbf{Q} \times \mathbf{r}_0) - (\mathbf{Q} \times \mathbf{r}_0, \mathbf{r}) \nabla F), \mathbf{n}),$$

здесь $F = a(ar + r^2 - (\mathbf{r}_0, \mathbf{r}))$,

$$\nabla F = (a^2 r^{-1} + a^{-1}(\mathbf{a}, \mathbf{r}) + 2a + 2r)\mathbf{r} - (a + 2r + a^{-1}(\mathbf{a}, \mathbf{r}))\mathbf{r}_0,$$

$$\mathbf{a} = \mathbf{r} - \mathbf{r}_0, \quad a = |\mathbf{a}|, \quad r = |\mathbf{r}|, \quad |\mathbf{n}| = 1.$$

Можно получить спектральное разложение магнитного поля в сферической системе координат в виде ряда по ортонормированным сферическим функциям $Y_{lm}(\theta, \phi)$ [1,2], определенных через присоединенные функции Лежандра $P_l^m(\cos \theta)$:

$$B(\theta, \phi) = \sum_{l=0}^N \sum_{m=0}^l A_{lm} Y_{lm}(\theta, \phi).$$

Коэффициенты разложения A_{lm} вычисляются по формуле

$$A_{lm} = \int_0^{2\pi} \int_0^{\pi} B(\theta, \phi) Y_{lm}(\theta, \phi) \sin \theta d\theta d\phi.$$

Данная работа предполагает проведение полной обработки исследуемого сигнала в пространстве коэффициентов Фурье разложения, в которых содержится вся информация о сигнале. Поэтому вывод аналитических зависимостей для получения искомым оценок и характеристик через коэффициенты разложения является актуальной и важной задачей и открывает возможности компактной обработки экспериментальных данных. Выведены аналитические соотношения в пространстве коэффициентов разложения для реализации операций математического анализа, например, вычисления производной, при использовании ортогональных сферических гармоник, зависящих от двух переменных. Работа выполнена при поддержке РФФИ, проекты 04-02-17368, 04-01-00756.

Литература

1. Dedus F.F., Makhortykh S.A., and Ustinin M.N. Application of the Generalized Spectral-Analytic Method in Information Problems // Pattern Recognition and Image Analysis, Vol. 12, No. 4, 2002, pp.429-437.
2. 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.
3. Sarvas J. Basic mathematic and electromagnetic concepts of the biomagnetic inverse problem. // Phys. Biol., Vol. 32, N 1, 1987, pp. 11-22.
4. Устинин М.Н., Махортых С.А., Молчанов А.М. и др. Задачи анализа

данных магнитной энцефалографии. В кн. Компьютеры и суперкомпьютеры в биологии. М.: Институт компьютерных технологий, 2002. С. 327-349.

Анализ ритма и определение темпа музыкальных произведений

Д.А. Курганский
(Москва)

Введение

Анализ ритма является важной составляющей в задаче распознавания музыки [1]. Акустические события, из которых состоит музыкальное произведение, такие как начала нот, ударные, паузы и др. образуют временной ряд, который и является предметом анализа в данной работе.

Как известно в теории музыки, музыкальное произведение подразделяется на такты, которые в свою очередь делятся на доли. Каждая нота занимает определенное положение в этой временной сетке, но далеко не каждой позиции в сетке соответствует нота. Кроме того, часто используются различные ритмические украшения (триоли, форшлаги, и т. д.) которые не укладываются во временную сетку. Поставленная задача заключается в нахождении положений тактов и долей, основываясь на знании времени начала нот.

Дополнительную трудность создает тот факт, что при живом исполнении темп произведения меняется с течением времени. Например, исполнитель может акцентировать конец части или произведения, замедляя темп исполнения.

Определение темпа музыкального произведения

Основным рассматриваемым акустическим событием является начало ноты (onset). Предполагается, что все начала нот в музыкальном произведении могут быть уложены во временную сетку татумов (tatum grid) – минимальных ритмических единиц произведения. При этом татум может соответствовать как доле такта, так и какой-то ее части. Последовательность татумов не обязательно строго равномерна, но характерное время изменения темпа должно быть много больше интервала следования татумов.

Согласно этим предположениям, интервал между началами любых двух нот (межонсетный интервал) должен быть кратен величине татума. Введенная в работе [1] функция ошибки остатка (reminder error function - REF) имеет минимумы в точках возможного периода татума:

$$e(p) = \sum_{i=1}^n \left(\frac{o_i}{p} - \left[\frac{o_i}{p} + \frac{1}{2} \right] \right)^2 \quad (1)$$

Используются расстояния не только между началами соседних нот, но и между всеми нотами, расстояние между которыми не превышает характерного времени изменения темпа (этот параметр в работе задавался эмпирически и составлял около 10 с). Для того, чтобы учесть изменение темпа во времени, каждый член входил в сумму (1) с весом, экспоненциально уменьшающимся с удалением межконшетного интервала от анализируемой точки. Глобальный минимум этой кривой должен соответствовать наиболее вероятному темпу.

К сожалению, данный подход имеет несколько недостатков. Во-первых, он рассчитан на квази-стационарный ритм, не имеющий тенденций к ускорению или замедлению. Функция REF, вычисленная в области интенсивного изменения темпа, не несет полезной информации. Во-вторых, описанный алгоритм осуществляет локальный анализ, и поэтому любой достаточно сложный ритмический рисунок существенно ухудшает точность определения темпа. Подобный подход, основанный на построении гистограммы межконшетных интервалов [2], на практике также имеет ограниченную область применения.

Глобальный анализ ритмической структуры

Для решения более общей задачи автор предлагает использовать схему «классной доски» (blackboard) [3]. Анализируемым параметром является время начала ноты. Строятся версии, описывающие предполагаемые положения татумов. Двигаясь по последовательности нот, проверяется соответствие предсказания и имеющихся данных. Если время начала дальнейших нот не может быть «объяснено» ни одной из имеющихся версий, то создается новая версия, а другие версии штрафуются.

Такая схема имеет целый ряд преимуществ. Она не предполагает стационарного ритма в произведении, и сложные ритмические картины мало влияют на измерение темпа. Кроме того, полученная версия-победитель автоматически содержит данные не только о периоде, но и о положении сетки татумов. Чрезвычайно важной представляется также возможность расширения системы для поиска сильных долей, характерных ритмических рисунков и пр. без изменения архитектуры.

Литература

1. Jarno Seppänen. Computational model of musical meter recognition. // Master of Science Thesis, 2001.
2. Kristoffer Jensen and Tue Haste Andersen. Beat Estimation On the Beat // IEEE Workshop on Applications of Signal Processing to Audio and Acoustics, pp. 87-90, 2003.
3. D.P.W. Ellis. Prediction-driven computational auditory scene analysis. // Ph.D. thesis, Dept. of Elec. Eng & Comp. Sci., M.I.T., 1996.

Построение математической модели организации медицинской помощи пострадавшим при ЧС

Т.И. Лучшева
(Новосибирск)

Введение

Методы построения логико-вероятностных моделей сложных объектов или явлений на основе анализа эмпирической информации находят широкое применение в ряде трудноформализуемых областей исследования. Логико-вероятностные модели представляются списком логических закономерностей, отражающих внутренние причинно-следственные связи сложных объектов и обладающих достаточно высокой прогнозирующей способностью. На основе полученных закономерностей строится решающая функция распознавания в пространстве разнотипных переменных в классе логических решающих функций [1]. Предложен метод нахождения закономерностей [2], который применялся при решении прикладной задачи, описанной ниже.

Математическая модель организации помощи пострадавшим

В связи с ростом количества техногенных и природных ЧС, сложностью прогнозирования количества пораженных в них людей, степени тяжести их поражения, а также расчета сил и средств для медицинского обеспечения массовых санитарных потерь на догоспитальном и госпитальном этапах, возникает необходимость построения математической модели организации медицинской помощи пострадавшим при ЧС на конкретно взятой территории (на примере Новосибирской области).

Формализация модели состоит из следующих составляющих:

- a) сортировка пострадавших в аварии по типам поражения (тип травмы, включая комбинированный тип поражения, и степень поражения) с последующим указанием числа пострадавших в зависимости от типа поражения.
- b) Использование экспертной информации о вероятности выживания человека для каждого типа и степени поражения в зависимости от времени оказания первой медицинской помощи, доврачебной помощи, первой врачебной помощи, квалифицированной помощи, специализированной помощи. Для получения указанной экспертной информации формулировался специальный опросник для врача-специалиста в виде логических экспертных высказываний.
- c) Построение логико-вероятностной модели на основе анализа логических экспертных высказываний.
- d) описание ситуации на месте аварии: число и характеристика стационаров, находящихся вблизи очага аварии (вместимость стационара,

квалификация и число бригад врачей), расстояние до места аварии, тип дороги и т.п.

е) моделирование наилучшей организации помощи пострадавшим при заданной сетке стационаров.

Такая постановка задачи позволяет:

1) Анализировать качество принятия решений по организации медицинской помощи пострадавшим в уже произошедших авариях.

2) Давать рекомендации по организации медицинской помощи при возникновении аварий, что даст возможность принимать наилучшие решения в каждый данный момент в реальном масштабе времени. Это окажет существенную помощь при принятии решений в сложной, быстро развивающейся динамической ситуации.

3) Определять оптимальное количество медицинских формирований, участвующих в ликвидации медико-санитарных последствий ЧС на конкретно взятой территории, а также давать рекомендации по их оснащенности.

Логико-вероятностная модель выживаемости пострадавших

Построение логико-вероятностной модели на основе анализа логических экспертных высказываний состоит в обобщении экспертных данных и нахождении списка логических закономерностей. Логической закономерностью называется высказывание, обладающее большим прогнозирующим свойством. Для термического типа поражения были найдены закономерности, например, для крайне тяжелой степени закономерность

Если (Первая медицинская помощь оказана) и (Доврачебная помощь оказана от 10 до 15 мин), то вероятность выживания от 7,5% до 15% с вероятностью 1, от 0% до 7,5% с вероятностью 0.

Моделирование наилучшей организации помощи пострадавшим

Предложена постановка оптимизационной задачи, которая заключается в поиске плана привлечения медицинских формирований, минимизирующего полные затраты времени на ликвидацию медицинских последствий ЧС при ограниченных ресурсах (число и оснащенность медицинских формирований, находящихся вблизи очага аварии).

Работа выполнена при поддержке проекта РФФИ № 04-01-00858а.

Литература

1. Лбов Г.С., Старцева Н.Г., Логические решающие функции и вопросы статистической устойчивости решений // Новосибирск, изд-во Института математики, 1999.
2. T.I. Luchsheva, Construction of mathematical model for analysis of the anthropological data // Pattern Recognition and Information processing, Minsk, 2003

Математические модели эволюции и регуляции экспрессии генов

В.А. Любецкий

Москва

Модель эволюции генов

Модель основана на: построении филогенетического дерева генов, а затем и дерева видов бактерий и вычислениях связанных с ними параметров на основе молекулярных данных; и также на анализе гипотез об эволюционных событиях молекулярного уровня у бактерий.

К упомянутым событиям, прежде всего, относятся: дивергенция генов в процессе дивергенции видов, дупликация генов, потеря и приобретение генов, горизонтальный перенос генов. Молекулярные данные – это наборы белковых последовательностей, объединенных по сходству и по выполнению определенной функции, и, в первую очередь, комплексы ортологических групп белков. Общая схема реконструкции эволюционных событий молекулярного уровня такова: отбираются белковые семейства и решается задача построения их множественных выравниваний, затем задача построения соответствующего филогенетического дерева генов G . Дальнейший анализ основан на использовании сходства (при построении дерева видов S) и различия (при анализе эволюционных событий) между многими филогенетическими деревьями генов $\{G_i\}$ и этим S . А именно, при построении дерева видов S различия в топологиях белковых деревьев G_i подавляются и находится «консенсусное» для них дерево. При анализе эволюционных событий, напротив, ищутся существенные различия в топологии отдельного белкового дерева G (часто G это одно из деревьев того же семейства $\{G_i\}$) и уже построенного дерева видов S . Для объяснения этих различий рассматриваются математические модели эволюции генов, а события эволюционной истории семейства микроорганизмов реконструируются путем оптимизации параметров этих моделей. А именно, в качестве модели эволюции берется так или иначе организованное сравнение деревьев белков и видов, а в качестве параметров – множества вершин этих деревьев и отнесенных к ним эволюционных событий. Оптимизация состоит в том, что ищутся такие значения этих параметров, на которых характеристики эволюции принимают экстремальные значения.

Модель регуляция экспрессии генов

Предлагается модель, в первую очередь, классической РНКовой регуляции экспрессии генов с помощью прерывания (терминации) процесса транскрипции. Модель опирается на представление о макросостоянии вторичной структуры в регуляторной области РНК между рибосомой и полимеразой, на формулы резонансного типа, определяющие

величину замедления РНК-полимеразы набором шпилек в той же области, на представления о процессах посадки и последующего движения рибосомы и полимеразы. Специальное внимание уделяется подбору параметров модели. Для проверки модели проведено компьютерное моделирование и получены, в частности, зависимости вероятности терминации транскрипции от величины концентрации загруженных тРНК и от концентрации аминокислоты в клетке или в культуре для многих регуляторных областей в геномах бактерий (здесь данные приводятся для четырех стрептомицетов) и при различных значениях трех параметров, которые рассматриваются как основные. Полученные зависимости согласуются с доступными экспериментальными данными; в том числе, по форме графиков, относящихся к активности фермента в зависимости от концентрации аминокислоты (например, атранилат синтазы от триптофана в культуре у *S. venezuela*).

Белок-ДНКовая регуляция транскрипции, как и секвестор трансляции, находят отражение в предлагаемой модели, но их подробные разработки будут представлены в другой статье.

В дальнейшем на основе нашей модели предполагается получить предсказания о влиянии точечных «мутаций» в регуляторных областях геномов на результат аттенуаторной регуляции, включая предсказания об эволюционной устойчивости организмов. А затем – включить эту модель в более широкую модель регуляции и метаболизма у бактерий. Другое возможное использование: сейчас аттенуаторная регуляция предсказывается обычно на основе множественного выравнивания, для этого требуется несколько последовательностей; получение с помощью модели на индивидуальной последовательности характерной для аттенуации или ее отсутствия кривой при подходящих параметрах могло бы рассматриваться как аргумент в пользу наличия или отсутствия аттенуации.

При построении этих моделей используются математические методы, в том числе распознавание образов. Указанных модели характеризуются весьма высокой вычислительной сложностью. Поэтому нами были разработаны специальные приемы построения быстрых алгоритмов (полиномиальных невысокой степени вместо естественно возникающих здесь сверхэкспоненциальных), и использовались параллельные вычислительные архитектуры, включая специальную организацию памяти при вычислениях.

Литература

1. Vitreschak A.G., Lyubetskaya E.V., Shirshin M.A., Gelfand M.S., Lyubetsky V.A. Attenuation regulation of amino acid biosynthetic operons in proteobacteria: comparative genomics analysis // FEMS Microbiol Lett. 2004 May 15; 234(2), p. 357-370.

2. Seliverstov A.V., Putzer H., Gelfand M.S., Lyubetsky V.A. Comparative analysis of RNA regulatory elements of amino acid metabolism genes in Actinobacteria // BMC Microbiology, 2005, accepted in press.

Масштабируемые алгоритмы классификации текстов

А.В. Максаков

(Москва)

Введение

Несмотря на то, что проблема классификации текстов достаточно хорошо изучена на данный момент, достаточно актуальным остается прикладной аспект теории машинного обучения. Известно множество алгоритмов, обеспечивающих сравнительно высокую точность классификации, в частности, метод опорных векторов[1] (SVM). Однако их высокая вычислительная сложность и ресурсоемкость делает проблематичным их использование в задачах, требующих обработки большого количества документов в процессах обучения и классификации. По этой причине актуальным представляется поиск масштабируемых и сравнительно быстрых алгоритмов классификации, точность которых была бы сравнима с вышеуказанными алгоритмами.

Модификация наивного алгоритма Байеса

В последнее время в литературе точность наивного алгоритма Байеса оценивается как одна из самых низких среди рассматриваемых алгоритмов. Тем не менее на практике он используется достаточно часто, причиной этому служит его простота и высокая производительность. У алгоритма есть несколько систематических проблем. В частности, он основан на принципе независимости признаков, также точность классификации существенно падает при наличии неравномошных обучающих выборок.

Вероятность принадлежности документа классу в алгоритме определяется следующим образом:

$$p(C | d') = \frac{p(d' | C)p(C)}{\sum_{C \in c} p(d' | C)p(C)} = \frac{p(C) \prod_{w \in d'} (p_{Cw})^{f_w}}{\sum_{C \in c} p(C) \prod_{w \in d'} (p_{Cw})^{f_w}}$$

где f_w - количество вхождений лексемы w в документ,

$$p_{Cw} = p(w | C)$$

Прологарифмировав обе части и убрав общие для всех классов слагаемые получаем следующее правило определения класса для документа:

$$C(d) = \arg \max_C [\log(p(C)) + \sum_{w \in d} f_w \log p_{Cw}]$$

Для борьбы с некорректным определением параметров в случае неравномоощных обучающих выборок, предлагается использовать парадигму класса-дополнения, то есть вместо вероятности принадлежности лексемы классу оценивать вероятность принадлежности лексемы классу-дополнению C' (следует учесть, что чем меньше $p(d|C')$, тем больше $p(d|C)$). Используя принцип сглаживания параметров по Лапласу получаем следующее правило:

$$C(d) = \arg \max_C [\log(p(C)) - \sum_{w \in d} f_w \log(\frac{\bar{N}_{Cw} + 1}{\bar{N}_C + |V|})]$$

где \bar{N}_{Cw} - количество лексем во всех классах кроме данного, \bar{N}_C - общее количество лексем в классе-дополнении, $|V|$ -размерность словаря лексем.

Для дальнейшего улучшения качества классификации предлагаются следующие приемы:

- Логарифмическое сглаживание частоты признаков
- Нормализация весов признаков в документе по его длине
- Использование инверсной частоты признака (IDF)
- Нормализация логарифмов весов признаков ($\log(p_{Cw})$)

Эксперименты показали улучшение точности классификации при включении всех эвристик, кроме логарифмического сглаживания и использования инверсной частоты. В результате при задаче классификации N классов ($N \gg 2$) точность такого алгоритма (MNB) сравнима с точностью SVM и существенно превосходит точность базового алгоритма (NB).

Алгоритм ModSimpl

Для задачи разделения двух классов внесенные модификации не позволяют приблизить алгоритм Байеса по качеству к лучшим показателям (парадигма классов-дополнений не вносит никаких изменений), поэтому для данного случая предлагается использовать алгоритм ModSimpl. Идея алгоритма состоит в последовательном нахождении направлений (как правило, не более 3-4), соответствующих дискриминанту Фишера[3], максимизирующему

$$J(a) = \frac{\left(\frac{1}{|x|} \sum_{x \in X} (x, a) - \frac{1}{|y|} \sum_{y \in Y} (y, a)\right)^2}{\frac{1}{|x|} \sum_{x \in X} (x, a)^2 - \left(\frac{1}{|x|} \sum_{x \in X} (x, a)\right)^2 + \frac{1}{|y|} \sum_{y \in Y} (y, a)^2 - \left(\frac{1}{|y|} \sum_{y \in Y} (y, a)\right)^2}$$

Вдоль такого направления можно эффективно разделить часть обучающих экземпляров. В дальнейшем возможно два сценария: либо спроецировать все экземпляры на полученное малоразмерное пространство и использовать внешний алгоритм, например С4.5[2], либо использовать точки отсечения для положительных и отрицательных экземпляров вдоль каждого направления. В ходе экспериментов второй вариант показал более точные результаты.

Схема обучения алгоритма выглядит следующим образом:

1. Методом адаптивного градиентного спуска находим локальный максимум $J(a)$
2. Проецируем все обучающие экземпляры на полученное направление и запоминаем точку оптимального разделения классов, а также полупрямые, содержащие только положительные и отрицательные экземпляры.
3. Отбрасываем корректно классифицированные экземпляры на данном направлении и повторяем шаги 1-3 до достижения пустого множества экземпляров или фиксированного числа итераций

Классификация экземпляра производится по следующему алгоритму:

цикл $i = 1 \dots$ количество направлений

Анализируем i -ое направление

если документ находится на полупрямой положительных или отрицательных документов, выдаем соответствующую метку и выходим из цикла

если данное направление последнее, определяем метку экземпляра с помощью точки оптимального разделения классов

конец цикла

Алгоритм обучения требует $O(|D|+|V|)$ байт в памяти и $O(|D| \cdot \log(|D|) + |D| \cdot |V|)$ операций, что существенно меньше требований алгоритма SVM. Точность алгоритмов при этом достаточно близка.

Результаты экспериментов

При проведении экспериментов использовался тестовый набор нормативных документов (150 классов, 6400 документов, 40% документов – обучающие экземпляры) семинара ROMIP (<http://romip.narod.ru>).

Таблица 1. Точность алгоритмов классификации.

	NB	MNB	ModSimpl	ModSimp+C4.5	SVM
точность	5,08%	45,46%	44,54%	35,58%	47,39%

Заключение

В рамках данной работы был предложен ряд изменений для наивного алгоритма Байеса, для которого, несмотря на его простоту и грубость предположений, в задачах с большим количеством классов удалось добиться высокого качества результатов. Для решения задачи бинарной классификации предложен масштабируемый алгоритм ModSimpl.

Литература

1. T. Joachims. Making large-scale SVM learning practical// Advances in kernel methods: support vector learning, MIT Press, 1999
2. R. Quinlan. C4.5: Programs for Machine Learning// Morgan Kaufmann Publishers, 1993
3. S. Chakrabarti. Mining The Web Discovering Knowledge From Hypertext Data// Morgan Kaufmann Publishers, 2003

Линейный дискриминант Фишера в задачах распознавания биосигналов по частотным свойствам

Л.А. Манило
(С.-Петербург)

Известно, что в организме человека происходят сложные динамические взаимодействия различных систем, которые отражаются в волновом характере многих процессов управления его физиологическими функциями и определяют сложный гармонический характер регистрируемых сигналов. Преобразование сигналов в частотную область позволяет оценить выраженность основных гармонических компонентов и выявить различия в спектральном составе сигнала. Получаемая при этом информация может служить основой для формирования набора признаков и построения решающих правил для распознавания некоторых состояний биообъекта, связанных с возникновением функциональных нарушений или развитием патологий. Задачу распознавания сигналов в этом случае можно решить путем выбора ограниченного числа содержательных признаков, получаемых в результате анализа спектральной плотности мощности сигнала (СПМ), и использования линейного дискриминанта Фишера для построения разделяющей функции. Однако, часто, несмотря на очевидность различий выбранных спектральных оценок, сформировать эффективный набор классификационных признаков довольно сложно. Здесь требуется определенный опыт в области прикладного спектрального анализа, который не всегда гарантирует успех. Более эффективной представляется задача формирования оптимального классификационного

описания, опирающегося на рассмотрение полного ряда спектральных коэффициентов как упорядоченного набора признаков. Для ее решения может быть предложена следующая процедура, основанная на их двухэтапной группировке.

На первом этапе формирования признаков строится исходное спектральное описание $G_i^{(0)} = G^{(0)}(f_i), i = 1 \dots N/2$, где N – число анализируемых отсчетов сигнала, а затем в пошаговом режиме попарно объединяются соседние спектральные коэффициенты. Для произвольного k -го шага рекуррентная формула осреднения оценок СПМ принимает вид:

$$G_i^{(k)} = (G_{2i-1}^{(k-1)} + G_{2i}^{(k-1)})/2,$$

$$i = 1 \dots N/2^m, m = k + 1,$$

где k – номер шага итерации.

Применив эту операцию как многошаговую процедуру, можно получить несколько векторов спектральных признаков $\bar{G}^{(k)}, k = 1, 2, \dots$.

При этом на каждом следующем шаге размер выборки сокращается в 2 раза и с ростом номера итерации формируются все более сглаженные оценки спектра мощности. Для выбора наилучшего частотного описания сигнала можно использовать один из критериев эффективности, характеризующий взаимное расположение двух групп объектов в спектральной области. В качестве показателя эффективности распознавания классов А и В может быть использован критерий линейного дискриминанта Фишера, который принимает максимальное значение в условиях наилучшей классификации:

$$J = \frac{|m_a - m_b|^2}{\tilde{s}_a^2 + \tilde{s}_b^2},$$

где m_a и m_b – математические ожидания спроектированных точек;

$\tilde{s}_a^2 = \sum (y - m_a)^2$ и $\tilde{s}_b^2 = \sum (y - m_b)^2$ – разброс проекций

выборок на ось решений; $\tilde{s}_a^2 + \tilde{s}_b^2$ – полный разброс внутри классов.

В общем случае для оценки меры близости классов А и В на k -ом шаге можно пользоваться обобщенным расстоянием, вычисляемым как среднее арифметическое всевозможных расстояний между всеми объектами рассматриваемых групп:

$$\rho^{(k)}(A, B) = (1/n_a n_b) \cdot \sum_{\overline{G}_l^{(k)} \in A} \sum_{\overline{G}_j^{(k)} \in B} \rho\left(\overline{G}_l^{(k)}, \overline{G}_j^{(k)}\right),$$

где n_a и n_b - число объектов, образующих классы А и В.

В результате выбора описания, соответствующего максимуму функции эффективности, формируется наилучший набор спектральных признаков $G_i, i = 1, 2, \dots, N_1$, где N_1 - число сглаженных оценок СПМ.

На втором этапе применяется процедура группировки спектральных коэффициентов путем суммирования их значений в границах заданных областей. Цель этой процедуры заключена в снижении размерности описания, полученного на первом этапе обработки, и повышении информативности частотного представления за счет введения оценки суммарной мощности сигнала в наиболее значимых для распознавания спектральных областях. Вначале задается максимально допустимое число интервалов M , в пределах каждого из которых объединяются точечные оценки сглаженной СПМ. Это значение определяет и число признаков, которые могут быть использованы при построении дискриминантных функций. Перебор вариантов расположения границ областей позволяет

получить набор векторов $\{\overline{G}^{(M)}\}$, из которых наилучший вариант может быть определен по тем же критериям эффективности, которые использовались на первом этапе процедуры оптимизации. Аналогичные действия выполняются и на последующих шагах обработки, связанных с последовательным уменьшением числа интервалов ($M, M-1, M-2, \dots$), каждый из которых объединяет свой набор смежных спектральных коэффициентов. В результате формируется упорядоченный набор векторов $\left(\overline{G}^{(M)}, \overline{G}^{(M-1)}, \overline{G}^{(M-2)}, \dots\right)$, которые сравниваются друг с другом по

значениям оцениваемой целевой функции. Оптимальный набор спектральных признаков $G_1^*, G_2^*, \dots, G_p^*$ выбирается по критерию наилучшего взаимного расположения классов А и В. Он сформирован в виде суммарных значений СПМ по p частотным областям. Исследование предложенных процедур проведено на примере формирования спектральных признаков для классификации электрокардиосигналов (ЭКС) в частотной области с целью обнаружения желудочковой фибрилляции сердца на ранних стадиях ее появления. Все эксперименты выполнены на верифицированных выборках реальных записей ЭКС из стандартной базы МПТ-ВН.

В эксперименте вначале оценивался критерий делимости классов в пространстве содержательных признаков. Для исследования частотных свойств ЭКС были выбраны фрагменты сигнала длительностью 2 с, дискретизованные с частотой 250 Гц. Анализ особенностей частотного описания ЭКС позволил выделить два параметра: f_D - доминирующую частоту и ΔP - отношение мощности ЭКС в частотной полосе шириной 1,46 Гц, centered по f_D , к суммарной мощности в полосе частот 0,5- 40 Гц. Результаты вычислений показали, что при увеличении длины анализируемого фрагмента значение J повышается примерно в 2 раза ($J = 0,225$). Однако и при этом не удается решить задачу надежного обнаружения желудочковой фибрилляции. Далее эффективность распознавания оценивалась в пространстве формальных признаков, полученных путем суммирования значений СПМ по p частотным областям. Использование двухэтапной процедуры позволило получить следующие результаты: $p = 3, J = 0,293$; $p = 4, J = 0,909$; $p = 5, J = 1,331$. Построение решающей функции показало, что задача обнаружения фибрилляции желудочков сердца может быть решена путем формирования даже четырех частотных областей СПМ.

Таким образом, использование частотного описания ЭКС и достаточно формальной процедуры формирования набора спектральных признаков позволяет оптимизировать вид сглаженной оценки спектральной плотности мощности и осуществить выбор интегральных параметров при построении решающих правил с применением линейного дискриминанта Фишера.

Кластеризация изображений графем на основе непрерывного гранично-скелетного представления

А.А. Масалович
(Москва)

Введение

В данной работе рассмотрена задача кластеризации изображений символов печатного текста.

Известные попытки применить скелеты для распознавания символов основывались на использовании растрового представления скелета, а также структурного описания скелета для сравнения двух изображений. Такие механизмы не очень точны, так как они сильно чувствительны к мелким искажениям изображения символа. Основной идеей предлагаемого метода является использование непрерывного гранично-скелетного представления бинарного изображения [1,2].

Работа выполнена при поддержке РФФИ, грант 05-01-00542.

Непрерывный скелет изображения

Для произвольного черно-белого изображения в качестве аппроксимирующей полигональной области возьмем многоугольную фигуру, ограниченную многоугольниками минимального периметра, разделяющими черные и белые точки изображения.

Скелетом полигональной области (ПО) называется геометрическое место точек на евклидовой плоскости, имеющих не менее двух ближайших точек на границе ПО. Таким образом, каждой точке скелета соответствует окружность, касающаяся границы области как минимум в двух точках и не пересекающая границы области – *пустая окружность*. Скелет ПО можно представить в виде плоского графа.

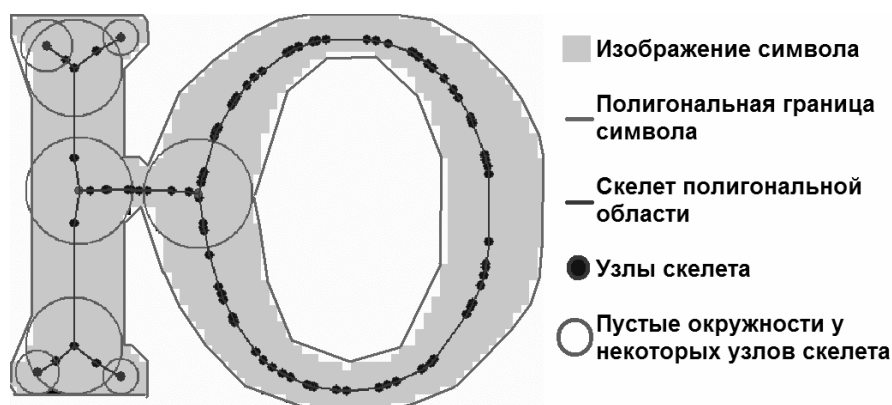


Рис.1 Изображение символа и скелет изображения символа.

Каждый *узел графа* – это точка на плоскости. Каждое *ребро графа* – это отрезок прямой, соединяющий точки, соответствующие двум узлам. *Степень узла графа* – это число исходящих из него дуг. Максимальная степень узла в скелете изображения буквы – 3.

Алгоритм кластеризации символов

Суть задачи кластеризации изображений символов состоит в разделении всего множества изображений на какое-то количество непересекающихся подмножеств (кластеров). При этом требуется, чтобы в один кластер попадали только изображения одного и того же символа. Также требуется, чтобы для одного символа количество кластеров, содержащих изображение этого символа, было минимальным. В оптимальном случае должно быть взаимнооднозначное соответствие символ-кластер.

Задача кластеризации символов возникает при распознавании печатных текстов как вспомогательная задача. Если перед распознаванием символы в тексте разделить на мелкие группы с одинаковыми символами, то

системе распознавания достаточно будет правильно распознать по одному представителю из этих групп, чтобы составить полную электронную версию документа.

Предлагаемый метод кластеризации отдельной графемы включает следующие шаги:

- Построение непрерывной границы и скелета бинарного растрового изображения графемы.
- Удаление в скелете мелких артефактов, появившихся в результате неровностей границы («стрижка» скелета).
- Последовательное сравнение скелета символа с описаниями кластеров.
- Выбор наиболее похожего на символ описания кластера.
- Уточнение описания выбранного кластера с помощью итерационного алгоритма в соответствии с обрабатываемым изображением.

Сравнение двух скелетов

Сравнение скелетов символов является центральным и наиболее сложным механизмом предлагаемого алгоритма. В основе сравнения лежит алгоритм вычисления функции близости двух скелетов.

1. Аргументы функции близости скелетов – два графа G_1, G_2 с взвешенными узлами. Множества элементов графов – S_1, S_2 состоят из множества ребер (B) и множества вершин (N). Каждое ребро – отрезок прямой на плоскости. Каждая вершина – точка на плоскости ($n.c$) с ассоциированной пустой окружностью (радиус окружности – $n.r$).
2. Нахождение узлов, имеющих степень больше 2
3. Сопоставление найденных узлов:

$$\rho(n_1, n_2) = \|n_1.c - n_2.c\| + |n_1.r - n_2.r|$$

4. Сопоставление ветвей между найденными узлами

$$\rho(s_1, s_2) = \max \left(\max_{n \in N_1} \rho(n, s_2); \max_{n \in N_2} \rho(n, s_1) \right)$$

$$\rho(n, s_i) = \min \left(\min_{n_i \in N_i} \rho(n, n_i); \min_{b_i \in B_i} \rho(n, b_i) \right)$$

5. Значение функции близости определяется как длина ветвей, которым не найдено соответствие в другом скелете

$$\rho(G_1; G_2) = \frac{\sum_{s \in S_1^*} |s| + \sum_{s \in S_2^*} |s|}{\frac{\sum_{s \in S_1} |s| + \sum_{s \in S_2} |s|}{2}}$$

$$S_i^* = \{s \in S_i \mid \neg \exists \bar{s} \in S_i : \rho(s; \bar{s}) < eps\}$$

Описание эксперимента

Распознается страница текста программой FineReader 7.0. Все изображения символов со страницы кластеризуются с помощью разработанной программы. Для каждого символа, ошибочно распознанного FineReader'ом, проверяется, в кластер с какими символами попадает этот символ. Если символ попадает в кластер с такими же как он символами и все остальные символы в кластере были распознаны правильно, это значит, что данная ошибка распознавания может быть исправлена при посткоррекции результатов распознавания при использовании описанного выше алгоритма кластеризации.

Таблица 1. Результаты работы алгоритма на тестовом примере

Число символов на странице	912
Неправильно распознанных символов	14
Качество распознавания	98,46%
Правильно кластеризованных ошибочных символов	5
Процент исправленных ошибок	35,7%
Ожидаемое качество	99,01%
Ожидаемое улучшение качества	0,55%

Заключение

Эксперименты доказали потенциальные возможности разработанного алгоритма для создания автономной системы распознавания. У методов есть несколько функциональных ограничений, однако они перекрываются другими существующими системами распознавания текстов. При этом в некоторых ситуациях (например, тексты с поврежденными символами) разработанные методы дают лучшее качество распознавания, чем современные системы. Таким образом, можно считать доказанным, что разработанные алгоритмы могут быть применены в реально существующих системах распознавания текстов в качестве вспомогательных механизмов и это приведет к заметному улучшению качества распознавания таких систем.

Литература

1. Местецкий Л.М.; Непрерывный скелет бинарного растрового изображения.; Труды межд.конф. «Графикон-98», Москва, 1998.
2. Местецкий Л.М., Рейер И.А.; Непрерывная гранично-скелетная модель дискретного изображения с контролируемой точностью аппроксимации.. Сб. XI Всероссийская конференция «Математические методы распознавания образов» (ММРО-11). Пущино, 2003.

Метод выделения границ объектов и слаборазличимых объектов на изображении, как предварительный этап решения задачи распознавания

В.Л. Матросов, С.М. Кулясов

(Москва)

Во многих системах распознавания изображений процесс разделяется на несколько этапов. В частности, часто на начальном этапе стараются преобразовать входное изображение в более удобный вид для решения задачи распознавания. В большинстве случаев, это сводится к выделению совокупности распознаваемых объектов на изображении. Важными характеристиками объектов на изображении являются их границы, а также мелкие объекты, являющиеся неотъемлемой частью этих объектов. В реальных же условиях, поступающие на вход системы распознавания изображения не всегда содержат полную информацию о границах и мелких объектах. Приведенный ниже метод предварительной обработки изображения, позволяет решить задачу выделения границ объектов и оконтуривания мелких слаборазличимых объектов.

На вход распознающей системы поступает цифровое изображение $Y(i, j)$, где $i = 1 \dots m - 1, j = 0 \dots n - 1$. Воспользуемся аддитивной моделью изображения, состоящей из двух компонент, каждая из которых содержит специфическую информацию о изображении [2]: $Y(i, j) = S(i, j) + K(i, j)$, где $S(i, j)$ – исходная локальная освещенность, $K(i, j)$ – фоно-объектовая составляющая. Исходная локальная освещенность формируется в результате многократного локально-несмещенного сглаживания [1] и несет в себе информацию только об освещенности изображения. Фоно-объектовая составляющая определяется в виде разности $K(i, j) = Y(i, j) - S(i, j)$ и содержит информацию обо всех объектах изображения. Именно преобразованию второй компоненты изображения и служит предлагаемый метод предварительной обработки.

Преобразование фоно-объектовой составляющей происходит в два этапа. На первом, осуществляется оконтуривание образов всех объектов.

Основным назначением оконтуривания является некоторое усиление перепадов яркости на границах объектов. Второй этап предполагает нелинейное в целом изменение «амплитуд» образов всех объектов, проводящееся с целью усиления значений яркости невидимых и слаборазличимых малопиксельных объектов (контрастирование).

Оконтуривание $(K(i, j) \rightarrow K^*(i, j))$ включает несколько операций:

1. Одноразовое локальное-несмещенное сглаживание фоно-объектовой составляющей. В результате получаем $\tilde{K}(i, j)$, сохраняющую информацию о положении малопиксельных объектов только с «округленными» границами.

$$2. \dot{K}(i, j) = K(i, j) - \tilde{K}(i, j).$$

3. Обнуляем совсем малые значения модулей $\dot{K}(i, j)$:

$$\hat{K}(i, j) = \begin{cases} 0, & \text{если } |\dot{K}(i, j)| \leq \tau, \\ \dot{K}(i, j), & \text{если } |\dot{K}(i, j)| > \tau. \end{cases}$$

Параметр τ принимает одно из значений $\{0, 1, 2, 3\}$.

4. Нормируем значения $\hat{K}(i, j)$:

$$\check{K}(i, j) = \begin{cases} \Theta \cdot \hat{K}(i, j), & \text{если } |\hat{K}(i, j)| \leq \omega, \\ \omega, & \text{если } |\hat{K}(i, j)| > \omega, \end{cases}$$

где $\Theta \in [0, 2; 2]$, $\omega \in [3; 7]$.

$$5. K^*(i, j) = K(i, j) + \check{K}(i, j).$$

Функция контрастирования $(K^*(i, j) \rightarrow K'(i, j))$ будет иметь следующий вид:

$$K'(i, j) = \begin{cases} k \cdot K^*(i, j), & \text{если } |K^*(i, j)| \leq \delta, \\ \text{sign}(K^*(i, j)) k \delta \sqrt{\frac{|K^*(i, j)|}{\delta}}, & \text{если } |K^*(i, j)| > \delta. \end{cases}$$

Параметры k и δ задаются априори.

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 // Новые информационные технологии: материалы шестого научно-практического семинара. / Моск. гос. ин-т электроники и математики. – 2003. – С. 24-25.

Бинокулярный оптико-электронный диагностический комплекс

С.Ю. Мирошниченко, С.В. Дегтярев
(Курск)

В настоящее время широкое распространение получили автоматизированные комплексы для диагностики различных заболеваний. Наиболее перспективным подходом к созданию таких комплексов является использование оптико-электронных датчиков, позволяющих проводить быструю высокоэффективную бесконтактную диагностику. Использование двух видеодатчиков в таких комплексах позволяет повысить точность диагностики за счет анализа двух проекций исследуемого объекта.

Разработанный комплекс спроектирован по принципам двухуровневой архитектуры. На нижнем уровне находится бинокулярное устройство, выполняющее ввод и предобработку изображений. На верхнем уровне располагается управляющая ПЭВМ, содержащая программное обеспечение для обработки полученной информации, постановки диагноза, организации диалога с пользователем посредством графического интерфейса и конфигурирования комплекса.

Процесс предварительной обработки изображений состоит из 4-х этапов.

- 1) Формирование градиентного изображения при помощи дифференциального оператора Собела [1].
- 2) Утончение контурных линий с помощью алгоритма подавления точек не максимальной интенсивности [2].
- 3) Бинаризация градиентного изображения с использованием порогового оператора с гистерезисом [2]. Для автоматического выбора пороговых значений применяются σ - метод [3] и метод Отсу [4].
- 4) Кодирование контурных линий однопроходным нерекурсивным алгоритмом [5].

Изображения после предобработки в виде линейных контурных кодов передаются в ПЭВМ с использованием КПИ. ПЭВМ выполняет анализ полученных данных, состоящий из 4-х этапов.

- 1) Восстановление связности контуров, направленное на объединение линейных сегментов в исходные контуры [5].
- 2) Поиск информативных контуров, соответствующих исследуемым объектам.
- 3) Идентификация типов проекций объектов при помощи методов контурного анализа [6].
- 4) Определение параметров проекций исследуемых объектов, постановка диагноза и выдача результатов.

Для реализации бинокулярного устройства нижнего уровня выбран ЦСП TMS320C6000 фирмы Texas Instruments. Данный ЦСП обладает требуемыми параметрами быстродействия и имеет встроенный АЦП. Объем внутренней памяти достаточен для хранения двух полутоновых изображений. Межуровневая коммуникация осуществляется при помощи последовательного интерфейса USB 2.0 или беспроводного интерфейса 802.11g. Интерфейс USB 2.0 на настоящий момент является самым распространенным и позволяет отказаться от плат расширения и использовать ПЭВМ стандартной комплектации, тогда как 802.11g способен обеспечить комплекс высокой мобильностью.

Бинокулярный оптико-электронный комплекс используется для реализации различных способов диагностики, основанных на анализе изображений участков тела пациента. Примером может служить способ ранней диагностики тромбоза глубоких вен нижних конечностей, который основан на сравнении площадей изображений мягких тканей голени до и после пережатия поверхностных вен [5].

Разработанный бинокулярный оптико-электронный комплекс для диагностики заболеваний венозной системы способен проводить высокоэффективную диагностику в условиях сложного оптически неоднородного фона, наличия бликов и посторонних объектов на изображении за счет предварительной обработки изображения исследуемой конечности.

Литература

1. Методы цифровой обработки изображений / С.В. Дегтярев, С.С. Садыков, С.С. Тевс, Т.А. Ширабакина. Курск: КурскГТУ, 2001. 167с.
2. J.F.Canny. A Computational Approach to Edge Detection // IEEE Trans. Pattern Recognition and Machine Intelligence. Vol. 8, №6. 1986. pp. 679–698.
3. Miroschnichenko S.Yu., Degtyarev S.V., Rukavitsin Yu.A. Adaptive Choice of Global Threshold for Binarization of Gradient Images // Pattern Recognition and Image Analysis, Vol. 15, №1. 2005. pp. 249–251.
4. N.Otsu. A Threshold Selection Method from Gray-Level Histograms // IEEE Trans. Syst. Man Cybern. Vol. 9, №1. 1979. pp. 62–66.

5. Мирошниченко С.Ю., Мишустин В.Н., Дегтярев С.В. Распознающий аппаратно-программный диагностирующий комплекс // Изв. ВУЗов. Приборостроение. 2005. Т. 48, №2. С. 22–27.
6. Введение в контурный анализ и его приложение к обработке изображений и сигналов / Под ред. Я.А. Фурмана. М.:ФИЗМАТЛИТ, 2002. 592с.

Применение семантических полей словаря РОСС в задаче построения Модели Управления предикатного слова

Д.В. Михайлов, Г.М. Емельянов

(Великий Новгород)

Применение подхода «Смысл \leftrightarrow Текст» [2] при решении задачи установления семантической эквивалентности [4] текстов Естественного Языка позволяет использовать для сравнения смыслов конечное число корректно формализуемых предметно-независимых правил преобразований деревьев глубинного синтаксиса. Вместе с тем актуальной остается проблема автоматизации построения и анализа корректности Моделей Управления (МУ) новых слов. Информация МУ необходима для преобразования дерева синтаксического подчинения в глубинную синтаксическую структуру [2].

При использовании предложенного авторами подхода [4] к построению МУ на основе лексикографического толкования для каждой новой МУ строится описание характеризованного ролевого состава Лексического Значения [2] (ЛЗ, рис.1). ЛЗ соответствует Семантическому Классу [3] (СК) слова. Между отдельными ЛЗ путем сравнения содержания валентностей идентичной ролевой ориентации задается известное в теории Формального Концептуального Анализа (ФКА) [1] отношение «субконцепт-суперконцепт», чем достигается систематизация словаря МУ.




Рис. 1. Характеризованный ролевой состав лексического значения *арендовать*.

Тем не менее, при наличии у гипонима [1,4] семантических валентностей, производных [2] от валентностей гиперонима, имеет место проблема безошибочной идентификации отношения «субконцепт-суперконцепт» между ЛЗ. Примером таких валентностей может послужить валентность получателя (*Recip*) у глаголов СК «передача в распоряжение» и образованная от нее валентность контрагента (*Contrag*) у предикатов со

значением «купли-продажи» [4].

Как следует из приведенных Ю.Д. Апресяном примеров [2], сходства и различия валентностей устанавливаются оценкой близости СК гипонима и гиперонима плюс сравнением СК актантов. С этой целью *в настоящей работе для каждого из анализируемых Семантических Классов строится описание* совокупностью используемых в словаре РОСС [3] дескрипторов таксономических категорий (КАТ) и Семантических Характеристик (СХ) в виде утверждения базы фактов Visual Prolog'a :

$$\text{sf}(\text{SCl}, \text{SFLst}, \text{CAT}, \text{CATSubCl}), \quad (1)$$

где семантическому классу SCl ставится в соответствие список SFLst СХ слова в последовательности «более общая СХ – более специфическая СХ», таксономическая категория CAT слова и ее подкласс CATSubCl .

Применением описаний (1) введенное в [4] понятие суперконцепта ЛЗ расширяется следующим образом.

Пусть для ЛЗ семантического класса SCl (1) задано описание характеризованного ролевого состава, где семантическая интерпретация актанта задается составным объектом языка Пролог и включает название Role роли плюс список ActSClLst список возможных СК актанта :

$$\text{t_sem_act}(\text{Role}, \text{ActSClLst}). \quad (2)$$

ЛЗ семантического класса SCl1 : $\text{sf}(\text{SCl1}, \text{SFLst1}, \text{CAT}, \text{CATSubCl})$ считается суперконцептом для ЛЗ семантического класса SCl2 : $\text{sf}(\text{SCl2}, \text{SFLst2}, \text{CAT}, \text{CATSubCl})$, если в дополнение к определенным в [4] условиям при отсутствии у суперконцепта для актанта $\text{t_sem_act}(\text{Role1}, \text{ActSClLst1})$ актанта субконцепта с идентичностью ролевой ориентацией и показанным в [4] соответствием набора возможных СК существует актант $\text{t_sem_act}(\text{Role2}, \text{ActSClLst2})$ субконцепта :
 $\forall \text{ActSCl1} \in \text{ActSClLst1} \quad :$
 $\text{sf}(\text{ActSCl1}, \text{ASFLst1}, \text{CAT}, \text{CATSubCl}) \quad \exists \text{ActSCl2} \in \text{ActSClLst2}$
 $: \text{sf}(\text{ActSCl2}, \text{ASFLst2}, \text{CAT}, \text{CATSubCl})$, причем один из ASFLst1 и ASFLst2 содержит другой в качестве подсписка, а SFLst2 характеризуется тем, что если SFLst1 последовательно разбивается на подписки : $\text{SFLst1}_1 \cup \text{SFLst1}_2 \cup \dots \cup \text{SFLst1}_N$,
 $\forall i \neq j \quad \text{SFLst}_i \cap \text{SFLst}_j = \emptyset$, то $\forall \text{SFLst}_i, i = 1, \dots, N$ есть общий

подписок для SFLst2 и SFLst1.

Реализуя на рассмотренной в [4] совокупности ЛЗ предикатных слов расширенное нами отношение «субконцепт-суперконцепт» средствами Visual Prolog'a 5.2, имеем представленную на рис.2 верхнюю окрестность ЛЗ глагола *арендовать* (рис.1).

В целях оценки адекватности используемых наборов дескрипторов (прежде всего - CX) для описаний (1) в настоящей работе путем применения реализующего методы ФКА специализированного ПО ToscanaJ (<http://toscanaj.sourceforge.net/>) строится модель системы ЛЗ предикатных слов. При этом (рис.3) ЛЗ выступают в качестве объектов, а CX – в качестве атрибутов.

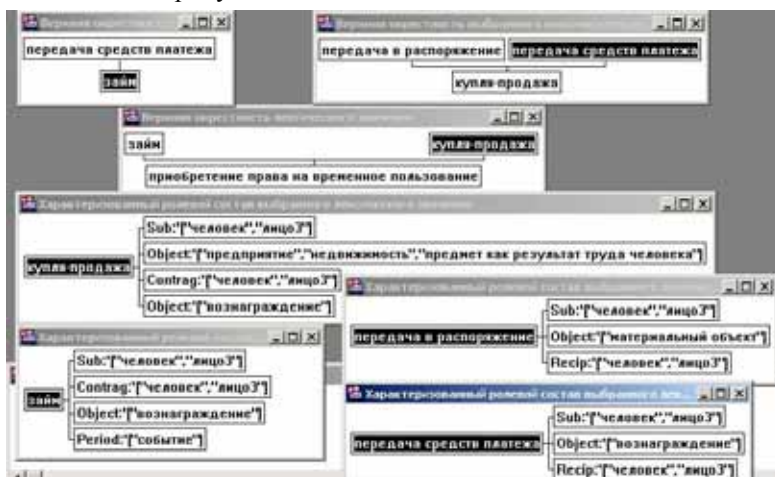


Рис. 2. Верхняя окрестность лексического значения глагола *арендовать*.




Рис. 3. Описания ЛЗ предикатных слов наборами CX.

Работа выполнена при поддержке РФФИ (проект №03-01-00055).

Литература

1. Maarten Janssen Differentiae Specificae in EuroWordNet and SIMuLLDA // Proceedings of OntoLex 2002 : Ontologies and Lexical Knowledge Bases conferences. Las Palmas, May 2002.
2. Апресян Ю.Д. Лексическая семантика. Синонимические средства языка. // Наука. Москва, 1974.
3. Леонтьева Н.Н. Русский общесемантический словарь (РОСС): структура, наполнение. // НТИ. Сер. 2. 1997. №12. С. 5-20.
4. Михайлов Д.В., Емельянов Г.М. Применение системы лексических значений предикатных слов для автоматизации пополнения словаря Моделей Управления // Интерактивные системы : проблемы человеко-компьютерного взаимодействия. VI Международная конференция. Ульяновск, Сентябрь 26-30, 2005. <http://old.ulstu.ru/conf/is/payment.phtml>

Использование методов компьютерной графики для генерации расчетных сеток в численных моделях океанов и морей

П.Н. Михеев
(Москва)

Современные модели океана строятся путем решения системы нелинейных дифференциальных уравнений, которые основываются на трех фундаментальных законах сохранения - массы, количества движения и энергии. Первый из этих законов дает возможность сформулировать уравнения неразрывности. Закон сохранения количества движения позволяет записать уравнения движения, а закон сохранения энергии - уравнение притока тепла. При этом учитывается перераспределение энергии путем турбулентного обмена, конвекции, а также взаимодействия с атмосферой. Подробное описание основных типов моделей океана и их приложений дается в работе [2].

Нерегулярность береговых очертаний океанических бассейнов осложняет применение спектральных методов численного интегрирования динамических уравнений, получивших широкое распространение в атмосферных моделях. При моделировании океана переход к конечномерному представлению исходных уравнений в частных производных обычно осуществляется на основе метода конечных разностей или конечных элементов. При численном решении уравнений переноса используют различные типы сеток, зависящие от горизонтального разрешения модели [1]. Для описания вихревых движений в океане, на долю которых приходится основная часть полной кинетической энергии, требуются модели с большим пространственным разрешением (порядка нескольких километров). В связи с этим особую важность приобретают вопросы, связанные с автоматизированным

построением расчетных сеток, позволяющих учесть ограничения свойственные моделям океана, а также очертания береговой линии.

В работе на примере Черного моря рассматриваются возможности использования методов компьютерной графики для генерации расчетных сеток с большим пространственным разрешением, учитывающих специфику береговой линии. Генерация координат ячеек сетки производится на основе заданных параметров: границы и количества узлов сетки по долготе и широте. Для построения маски суша/вода с учетом береговой линии используется модификация алгоритма двумерного отсечения Вейлера-Азертона [3]. Одним из преимуществ данного метода, в отличие от простых алгоритмов двумерного отсечения, например, Козна-Сазерленда [4], является возможность отсечения по невыпуклой области (береговой линии). Ценой такого преимущества является большая сложность и меньшая скорость вычислений.

Конечно-разностное представление системы уравнений налагает определенные ограничения на конфигурацию расчетной сетки вблизи береговой границы. Поэтому на втором этапе исследования, по аналогии с методами размывания или увеличения резкости в компьютерной графике, производится фильтрация полученной сетки. В результате маска суша/вода модифицируется таким образом, чтобы имеющиеся проливы содержали не менее двух, а заливы — не менее трех “водных” ячеек по каждому из направлений горизонтальной сетки. Этим достигается выполнение необходимых условий при замене частных производных соответствующими конечно-разностными отношениями в модели океана. На третьем этапе производится интерполяция в полученную сетку топографии с использованием данных из массива топографии Земли (ETOPO5) и визуализация полученных результатов.

Литература

1. Мезингер Ф., Аракава А. Численные методы, используемые в атмосферных моделях // Пер. с англ. – Л.: Гидрометеиздат, 1979. С. 133 – 136.
2. Реснянский Ю.Д., Зеленко А.А. Динамика водообмена между океаническими бассейнами и ее связь с атмосферными воздействиями в модели общей циркуляции океана // Фундаментальные и прикладные гидрометеорологические исследования. Санкт-Петербург. Гидрометеиздат, 2003. С. 150 – 181.
3. Weiler K., Atherton P., Hidden Surface Removal Using Polygon Area Sorting // SIGGRAPH'77 Proceedings, Computer Graphics, Vol. 11, N. 2, pp. 214-222, 1977.
4. Sutherland I.E., Hodgman G.W. Reentrant Polygon Clipping // Communications of the ACM, 17(1), pp. 32-42, 1974.

Биометрическая идентификация личности по электрокардиограмме

А.П. Немирко, Т.С. Луговая
(Санкт-Петербург)

В настоящее время биометрические технологии являются одной из самых быстро развивающихся областей информационной безопасности, постепенно проникающей во все сферы человеческой деятельности. На сегодняшний день только три биометрических метода доказали свою практическую ценность: распознавание по отпечаткам пальцев, радужной оболочке или сетчатке глаз и по чертам лица. Также в зависимости от целевой установки и области применения используется распознавание по геометрии рук, голосу, динамике подписи, ритму работы на клавиатуре и т. д.

В работе исследуется возможность построения биометрической системы идентификации личности на основе электрокардиограммы (ЭКГ) человека (рис. 1). Предполагается, что ЭКГ является достаточно уникальной характеристикой человека, поскольку морфология и амплитуды регистрируемых кардиокомплексов определяются множеством индивидуальных факторов, в частности, строением и положением сердца, наличием и характером патологий и т. д.



Рис. 1. Пример ЭКГ с принятыми обозначениями.

Возможность построения такой системы рассматривалась в [1, 2]. В данной работе предложены иные методы обработки и классификации данных, разработанная система идентификации тестировалась на гораздо большем объеме реальных исходных данных. Сравнение полученных результатов приведено ниже.

Разработанная система распознавания основана на классической схеме, включающей в себя предобработку, формирование исходного пространства признаков, переход в редуцированное пространство признаков и классификацию.

Исходя из соображений практической применимости системы, в работе использовались короткие записи ЭКГ (10-20 секунд), регистрируемые в одном отведении с рук человека (I отведение) с частотой дискретизации 500Гц и разрядностью 12.

На этапе предобработки реализована фильтрация сигнала от помех различного генеза средствами частотно-избирательной фильтрации и

коррекция дрейфа изолинии с помощью вейвлет-анализа.

Основной акцент в работе был сделан на формирование исходного пространства признаков. Очевидно, что информация об особенностях работы сердца в основном содержится во фрагменте кардиоцикла, содержащем комплекс QRS и зубцы Р и Т (далее PQRS-фрагмент). Поэтому на данном этапе сначала из ЭКГ выделяется набор PQRS-фрагментов, синхронизованных по зубцу R. Длительность PQRS-фрагментов фиксирована и составляет 0.5 с или 250 отсчетов. В качестве признаков PQRS-фрагментов используются их отсчеты. Далее выделенные PQRS-фрагменты подвергаются дополнительной обработке, повышающей их сходство, которая включает в себя:

- коррекцию «вертикального» смещения PQRS-фрагментов относительно друг друга из-за возможно оставшегося небольшого дрейфа изолинии;
- отбраковку возможных «нетипичных» PQRS-фрагментов, обусловленных, например, движением рук, форсированным дыханием или некоторыми патологиями;
- коррекцию PQRS-фрагментов в зависимости от частоты сердечных сокращений.

Таким образом, в исходном пространстве признаков размерности $N=250$ ЭКГ представляется набором PQRS-фрагментов, каждый из которых на последующих этапах работы системы рассматривается как отдельный образ и обрабатывается и классифицируется независимо от остальных.

Редукция пространства признаков реализуется с помощью анализа главных компонент (АГК), в результате которого размерность пространства можно сократить до 30 (по критерию Кайзера) или даже до 10 (по критерию каменистой осыпи). Альтернативно рассматривалась редукция пространства с помощью вейвлет-преобразования (ВП), оно давало такое же сокращение размерности, но результаты финальной идентификации были немного хуже.

Далее выполняется классификация полученных образов PQRS-фрагментов в редуцированном пространстве признаков с помощью линейного дискриминантного анализа.

На последнем этапе на основе полученных результатов классификации набора PQRS-фрагментов принимается решение о принадлежности всей ЭКГ некоторому классу.

Для экспериментальных исследований были накоплены ЭКГ 90 человек. Регистрация проводилась в положении сидя, при этом физическое состояние и частота сердечных сокращений не ограничивались. Исходная выборка ЭКГ составила 320 записей, 200 из которых использовались для обучения системы, и 120 - для тестирования. Разделение исходной

выборки на обучающую и контрольную преследовало цель максимально усложнить работу системы, т.е. записи в разных выборках максимально отличались по времени регистрации или физическому состоянию человека на момент регистрации.

Усредненные результаты серии экспериментов по распознаванию PQRST-фрагментов и ЭКГ при различных вариантах редуцирования пространства признаков и формирования обучающей и контрольной выборок представлены в таблице 1.

Таблица 1. Результаты экспериментов.

Метод редукиции	Количество признаков	Классификация PQRST-фрагментов, %		Идентификация ЭКГ контрольной выборки, %
		Обучающая выборка	Контрольная выборка	
АГК	10	99	85	89
ВП	9	98	79	82
АГК	30	99	91	96
ВП	34	99	88	91

Таким образом, уровень правильной идентификации ЭКГ составил 96%. Дополнительно, в таблице 2 приведены результаты, полученные в [1, 2] и данной работе.

Таблица 2. Сравнение результатов.

Работа	Количество классов	Результат идентификации, %
[1]	20	98
[2]	9	95
данная	90	96

В результате проведенных исследований была разработана система распознавания, решающая задачу биометрической идентификации личности по ЭКГ на достаточно большой выборке реальных исходных данных. Полученные результаты дают первичную положительную оценку возможности использования ЭКГ в качестве биометрической характеристики в различных задачах биометрического контроля доступа, что открывает новое направление исследований в области биометрических технологий и увеличивает потенциал развития систем безопасности и систем обеспечения удобства современной жизни.

Литература

1. L.Biel, O.Pettersson, L.Philipson, P.Wide "ECG Analysis: A New Approach in Human Identification", IEEE Transactions on Instrumentation and Measurement, vol.50, №3, June 2001, pp. 808-812.

2. W.J. Yi, K.S. Park, D.U. Jeong “Personal Identification From ECG Measured Without Body Surface Electrodes Using Probabilistic Neural Networks”.

О проблеме формализации понятия «плагиат» как о проблеме распознавания

Г.В. Никитов

(Москва)

На сегодняшний момент способ и форма несанкционированного использования авторами различных текстовых работ чужих идей и высказываний, иными словами, текстового плагиата, изменились, по сравнению с ситуацией в недалеком прошлом. Если раньше речь шла, прежде всего, о недобросовестном цитировании в литературных произведениях и научных работах, то теперь самым распространенным видом текстового заимствования стало непосредственное копирование фрагментов документов на компьютерах. В качестве источников для такого копирования выступают, в основном, текстовые документы, находящиеся в свободном доступе в сети Интернет. Большое количество потенциальных источников для заимствования и простота, с технической стороны, осуществления копирования позволяют говорить об актуальности проблемы обнаружения плагиата в текстовых документах. Это относится, в первую очередь, к сфере образования: высшей школе и средним учебным заведениям, где учащиеся в рамках учебного процесса сдают рефераты, курсовые и дипломные работы и другие тексты, для написания которых от их авторов требуется самостоятельная творческая деятельность.

В то же время, формальное определение того, какой фрагмент текста является плагиатом, а какой – нет, часто не может быть дано, в силу отсутствия единых критериев оценки у экспертов, анализирующих документы (в случае сферы образования в качестве экспертов обычно выступают преподаватели). В одном случае использование отдельного редкого слова эксперт может посчитать плагиатом, а в другом – целый скопированный абзац будет оценен как правомерное цитирование. Еще большая неопределенность возникает при оценке «деформированного» фрагмента, в котором был нарушен первоначальный порядок следования слов, а часть исходных слов, в свою очередь, была заменена синонимами.

Для решения проблемы формализации текстового плагиата предлагается использовать схему построения алгоритмического решения задачи с обучением на прецедентах. В качестве прецедентов берутся пары текстовых фрагментов, про которые известно, является ли один из фрагментов плагиатом второго или нет. Пары фрагментов, составленные таким образом, разбиваются на два класса: «плагиат» и «оригинальный

текст».

Далее проблема рассматривается в рамках алгебраического подхода к распознаванию, развитого академиком РАН Ю.И. Журавлевым, членом-корреспондентом РАН К.В. Рудаковым и их учениками. В качестве пространства допустимых объектов \bar{S} берется множество пар фрагментов текстов. Множество финальных информаций состоит из ответов вида «плагиат» – «оригинальный текст». По сути, элементы пространства допустимых объектов представляют собой пары предложений, абзацев, коротких последовательностей абзацев.

В дальнейшем предлагается рассматривать не само пространство допустимых объектов, а пространство допустимых описаний этих объектов. В качестве такого пространства берется множество признаков описаний объектов \mathfrak{S}_i (множество начальных информаций), для чего задается функция $D: \bar{S} \rightarrow \mathfrak{S}_i$, сопоставляющая каждому объекту его описание. Например, функция

$$D(S) = D(Fr_1, Fr_2) \in \mathfrak{R}_+^n, \text{ где } n - \text{число признаков,}$$

паре фрагментов текста сопоставляет числовой вектор. Каждая координата вектора есть некоторая величина, характеризующая данную пару. Это может быть, в частности, число общих слов во фрагментах, количество общих пар или другие характеристики.

Содержательно устройство функции D может быть описано следующим образом: чем большее значение принимают признаки описания объектов, тем с большей вероятностью эти объекты классифицируются как «плагиат». Существенным является дополнительное требование монотонности функционала: неравенство

$$D(S_1) < D(S_2), \text{ где } S_1 = (Fr_0, Fr_1), S_2 = (Fr_0, Fr_2)$$

выполняется только в том случае, если Fr_1 сильнее отличается (в каком-то смысле) от Fr_0 чем Fr_2 , или, другими словами, если Fr_1 более «деформирован», чем Fr_2 . Наконец, функция принимает значение единица в том случае, если один фрагмент полностью совпадает со вторым из пары: $D(Fr_0, Fr_0) = 1$. При наличии таким образом заданных пространств начальных и финальных информаций, возникает обычная задача классификации в n - мерном пространстве.

Принятое требование монотонности функционала исключает возникновение ситуации на прецедентах, когда на объекте обучения, у которого один из фрагментов больше деформирован, чем у другого

объекта обучения, функция, тем не менее, выдает значение большее, чем на втором объекте. Таким образом, это ограничение дает возможность вывести критерии разрешимости и регулярности задач.

Наконец, на основе критериев разрешимости и регулярности задач устанавливаются критерии суперполноты и полноты для моделей алгоритмов и их алгоритмических расширений. Под суперполнотой понимается разрешимость в рамках семейства всех разрешимых задач, а под полнотой – в рамках регулярных задач.

Литература

1. Журавлев Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики. — 1978. — Т. 33. — С. 5–68.
2. Журавлев Ю.И., Рудаков К.В. Об алгебраической коррекции процедур обработки (преобразования) информации // Проблемы прикладной математики и информатики. — 1987. — С. 187–198.
3. Рудаков К.В. Алгебраическая теория универсальных и локальных ограничений для алгоритмов распознавания. — Диссертация на соискание ученой степени д.ф.-м.н., М.: ВЦ РАН. — 1992.

Техническая дефектоскопия на основе методов стохастической геометрии

Т.В. Никифорова

(Москва)

Выполнение сварочных работ, согласно требованиям нормативных документов, сопровождается проведением радиографического контроля. Результаты расшифровки рентгеновских снимков сварных швов являются основой для заключения о качестве изделия. Построение системы технической дефектоскопии призвано автоматизировать процесс расшифровки рентгеновских снимков, уменьшить число ошибок, допускаемых в ходе контроля по причине утомляемости людей, сократить время проведения контроля.

Система, предназначенная для расшифровки рентгеновских снимков сварных соединений, должна определить наличие дефектов, место их расположения, тип, размер. В статье предложен алгоритм работы дефектоскопической системы, для реализации которого применяются методы современной теории распознавания образов.

Для описания дефектов сварных соединений на языке признаков наиболее целесообразным является применение теории распознавания образов, основанной на стохастической геометрии [1]. Особенность задачи дефектоскопии сварных соединений состоит в значительной вариативности формы дефектов и уровня их яркости, наличии фоновых шумов, обусловленных разбросом качества рентгеновской пленки.

Применение методов распознавания, основанных на стохастической геометрии, позволяет осуществить эффективную фильтрацию изображений и конструировать большое количество признаков распознавания изображений, что способствует преодолению нечеткости, присущей задачам дефектоскопии.

Формирование признаков изображения начинается с реализации геометрического преобразования изображений, связанного со сканированием по сложным траекториям, – *Trace*-преобразования (*Trace* от английского слова «след») [2]. Изображение F на входной сетчатке распознающей системы сканируется решеткой параллельных прямых $l(\rho, \theta)$, с расстоянием $\Delta\rho$ между линиями (рисунок 1). Параметры ρ и θ являются нормальными координатами линии l . Взаимное положение исследуемого изображения F и каждой сканирующей линии l характеризуют числом g , вычисляемым по некоторому правилу $T: g = T(F \cap l)$. В качестве указанной характеристики рассматривают свойства окрестности сечения изображения сканирующей линией. Отображение T является функционалом или *Trace*-функционалом. Результат вычислений T функционала зависит от двух параметров прямой θ и ρ . Далее сканирование производится для нового значения угла, получившего дискретное приращение $\Delta\theta$, решеткой линий с тем же шагом $\Delta\rho$.




Рисунок 1. Сканирование объекта решеткой параллельных линий в одном из направлений




Рисунок 2. *Trace*-матрица изображения сварного соединения с несколькими дефектами

При дискретном сканировании *Trace*-преобразование представляют в виде матрицы или *Trace*-матрицы, ось $O\theta$ которой направлена горизонтально, а ось $O\rho$ – вертикально (рисунок 2). Элемент *Trace*-матрицы, стоящий на пересечении i -й строки и j -го столбца, есть $g_{ij} = T(F \cap l(\theta_j, \rho_i))$, т. е. каждый столбец матрицы содержит значения, вычисляемые по всем прямым при одинаковом значении угла θ . Если прямая l не пересекает изображение, то $T(F \cap l)$ полагают равным

заданному числу. После заполнения Гаусс-матрицы ее столбцы обрабатываются с помощью диаметрального функционала P . Результатом этой обработки является π (2π) - периодическая функция. Воздействуя на нее круговым функционалом Θ , получаем некоторое число – признак изображения $\Pi(F)$. Таким образом, признак исследуемого изображения обладает структурой в виде композиции трех функционалов – триплетный признак $\Pi(F) = \Theta \circ P \circ T(F \cap I(\rho, \theta))$.

Данный подход обеспечивает возможность формирования большого числа признаков, отражающих различные особенности дефектов сварных соединений: особенности формы; структурные свойства – взаимное расположение и количество; геометрические параметры. Для рентгеновских изображений сварных соединений характерны значительные градации уровня яркости, различная степень зашумленности. На изображениях присутствует спекл-шум, связанный с зернистостью рентгеновской пленки и изменяющийся в широких пределах в зависимости от качества и типа пленки, а также шум, обусловленный механическими повреждениями рентгеновских снимков и т.д. Проведенные исследования показали возможность использования методов стохастической геометрии для предварительной обработки исследуемых изображений: осуществления нелинейной фильтрации с целью уменьшения зашумленности, полигональной аппроксимации, инверсии, квантования изображений [3]. Поскольку предложенные методы фильтрации реализуются в той же технике, что и вычисление признаков, появляется возможность совместить в одном такте сканирования предобработку изображений с вычислением признаков. Это ведет к выигрышу в быстродействии распознавания.

Выбор правила для принятия решения относительно класса исследуемого изображения обусловлен сложностью решаемой задачи:

- классы изображений различаются числом дефектов; от числа обнаруженных дефектов зависит дальнейшее описание изображения и, соответственно, выбор признаков для определения интересующих параметров.

- для описания дефектов используют признаки различной природы. Наряду с геометрическими характеристиками используются признаки, представляющие собой логические условия. Например, расположение дефектов вдоль одной прямой является одним из признаков принадлежности дефекта к классу цепочек пор или включений.

В такой ситуации принятие решения о принадлежности распознаваемого объекта к одному из классов осуществляется на основе логического решающего правила (CORAL) [4]. При построении высказываний учитывается логика решаемой задачи, геометрические особенности изображений и полученные значения признаков.

Разнообразие применяемых для распознавания признаков, инвариантность многих из них по отношению к поворотам, перемещениям и линейным деформациям, обеспечивают высокую надежность распознавания.

На основе рассмотренного подхода спроектирована и построена система автоматического распознавания дефектов сварных соединений. Экспериментальная проверка работы системы на массиве свыше полутора тысяч рентгеновских изображений реальных сварных соединений подтвердила высокую эффективность распознавания дефектов сварных соединений.

Литература

1. Федотов Н.Г. Методы стохастической геометрии в распознавании образов. – М.: Радио и связь, 1990. – 142 с.
2. Федотов Н.Г. Теория признаков распознавания образов, основанная на стохастической геометрии// Искусственный интеллект. – 2000. – № 2. – С. 207 – 211.
3. Никифорова Т.В. Методы предварительной обработки изображений на основе Трасе-преобразования// Материалы 11-й международной конференции, 2003. – С. 466 – 469.
4. Загоруйко Н.Г. Прикладные методы анализа данных и знаний. – Новосибирск: Изд-во Института математики, 1999

Анализ изображений и элементы цифровой диагностики в системе цифровой бесплёночной рентгенографии

М.М. Ольшевец

(Пушино)

В Пушкинском научном центре РАН коллективом авторов 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, анализа, обработки, хранения и распечатки цифровых рентгеновских изображений.

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
2. Хранение снимков и организация быстрого доступа к ним
3. Визуализация снимков и операции цифровой диагностики
4. Цифровая обработка снимков и печать на бумаге или пленке.

Относительно высокая зашумленность и низкая контрастность

получаемого снимка могут приводить к появлению артефактов при неправильно выбранном сценарии 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 [2].

В состав программного комплекса включены шаблоны нескольких известных операторов свертки при различных размерах окна (гауссиан, лапласиан, и др.), пользователь может выбрать наиболее подходящую операцию, последовательно применять фильтры, задать в диалоговом режиме произвольное окно и матрицу весов фильтра и сохранить созданный шаблон для дальнейшего исследования и анализа снимка.

Также реализованы некоторые нелинейные алгоритмы обработки изображений со скользящим окном, такие, как медианная фильтрация [2].

Наряду с шумоподавлением и повышением контрастности изображения важной задачей является сжатие цифровых рентгеновских снимков. Актуальность проблемы обусловлена необходимостью хранения большого числа полноформатных цифровых изображений и их передачи по каналам связи без потерь значимой диагностической информации. Для решения обеих задач использовались разложения по wavelet-базисам (базисам всплесков) [1], представляющим собой специфические системы ортогональных функций, хорошо подходящих для обработки резко меняющихся данных.

В программе также реализован алгоритм коррекции неравномерности яркости по полю снимка. Яркость снижается по мере удаления от центра изображения. Эта неравномерность является, с одной стороны, следствием высоких требований к используемой в приставке цифровой фотокамере, с другой стороны, свойством рентгеновского источника. Для коррекции этого дефекта применяется подход с использованием эталонного снимка, выполняемого при заданных условиях и не содержащего объектов. Этот снимок аппроксимируется с использованием различных алгоритмов и результат аппроксимации используется для коррекции целевых снимков. При аппроксимации происходит сглаживание точечных шумов, в то же время хорошо исправляется оптическая неравномерность поля снимка.

Такая коррекция необходима для реализованной в программе методики определения рентгеновской плотности снимаемых объектов (денситометрия) по цифровому рентгеновскому снимку. Методика предназначена для цифровой диагностики остеопороза – заболевания скелета, характеризующегося снижением плотности кости и нарушением структуры костной ткани. Для этого в поле съемки наряду с

диагностируемым объектом включается эталонный объект – ступенчатый металлический клин. Положение клина на цифровом снимке определяется полуавтоматически. Сравнивая яркости диагностического и эталонного объектов и зная реальную плотность ступенек клина, можно определить плотность ткани.

Полученные результаты и их дальнейшее развитие могут быть использованы для создания центров телемедицины и, в частности, методики массовой диагностики остеопороза на основе цифровых рентгеновских систем общего назначения.




Рис. 1. Фрагмент полноэкранного окна программы. Денситометрия цифрового снимка кисти руки.

Проводимые исследования выполняются при финансовой поддержке РФФИ (проекты 04-01-08087, 04-01-00814, 04-01-97228).

Литература

1. Mallat S. A Wavelet Tour of Signal Processing. Academic Press, Boston, 1998
2. Ross J. C. The image processing handbook. CRC Press, 1995.

Проблемы минимаксного оценивания в линейных неопределенно-стохастических системах

А.Р. Панков, К.В. Семенихин

(Москва)

В докладе представлены результаты исследований авторов в области минимаксного оценивания за последние семь лет. Объектом исследования являются линейные *обобщенные неопределенно-стохастические* модели наблюдения, которые охватывают следующие частные случаи:

- модели с неограниченными неслучайными параметрами и случайными шумами (классические регрессионные модели) [1, 2];
- стохастические модели со случайными параметрами и возмущениями с частично известными вероятностными характеристиками [3];
- модели с неопределенными параметрами, содержащимися в заданных множествах, и с неопределенными ограниченными шумами [4].

В соответствии с идеей А. Вальда [5] проблема построения наилучшей оценки $\hat{\xi}$ состояния системы ξ по измерениям η в условиях неполной априорной информации относительно модели наблюдения Z формулируется в виде оптимизационной задачи:

$$\hat{\xi} \in \arg \min_{\tilde{\xi} \in \Xi} \sup_{\zeta \in Z} D(\tilde{\xi}, \zeta),$$

где Ξ — класс допустимых оценок, Z —

множество возможных состояний расширенной системы $\zeta = (\xi, \eta)$, а $D(\tilde{\xi}, \zeta)$ — заданный функционал, значение которого определяет качество оценки $\tilde{\xi}$, если система находится в состоянии ζ .

В докладе рассмотрены следующие примеры функционалов $D(\cdot)$:

1. *среднеквадратический* $\text{MSE}(\tilde{\xi}, \zeta) = \mathbf{E} \left\{ \left\| \tilde{\xi} - \xi \right\|^2 \right\}$, где $\|\cdot\|$ — евклидова норма;
2. *квантильный* $\text{VaR}_{\varepsilon}(\tilde{\xi}, \zeta) = \min \left\{ \gamma : \mathbf{P} \left\{ \left\| \tilde{\xi} - \xi \right\| \leq \gamma \right\} \geq 1 - \varepsilon \right\}$, где ε — заданный уровень значимости;
3. *вероятностный* $\text{Pr}_{\gamma}(\tilde{\xi}, \zeta) = \mathbf{P} \left\{ \left\| \tilde{\xi} - \xi \right\| > \gamma \right\}$, где γ — заданный уровень ошибки.

Априорная информация о модели наблюдения задается в виде ограничений на совместное распределение \mathbf{P}_{ζ} случайных векторов $\xi \in \mathbf{R}^m$ и $\eta \in \mathbf{R}^n$. В докладе подробно разобран случай, когда множество допустимых распределений описывается ограничениями на первые два момента: $Z = \{ \zeta : \mathbf{E} \{ \zeta \} \in \mathbf{M}, \text{cov} \{ \zeta \} \in \Gamma \}$, где \mathbf{M}, Γ — множества возможных значений вектора математического ожидания и матрицы ковариаций случайного вектора $\zeta = (\xi, \eta)$.

Для решения задачи линейного минимаксного оценивания разработан метод, основанный на решении двойственной задачи [3, 6, 7]. Нахождение минимаксной оценки проводится в соответствии со следующей схемой:

1. вычисляется точная верхняя грань функционала (среднеквадратического, квантильного или вероятностного) на классе распределений с фиксированными моментами;
1. находится оценка, минимизирующая указанную верхнюю границу;
1. определяется решение двойственной (максиминной) задачи (т.е. наилучшие среднее и ковариация);
1. в выражение для оценки, найденной в п.2, подставляется решение

двойственной задачи.

Эффективность данной схемы решения обусловлена следующим:

- все выражения в пп.1 и 2 имеют аналитический вид;
- двойственная задача представляет собой конечномерную задачу выпуклого программирования с функционалом, также имеющим аналитическое представление;
- для решения двойственной задачи разработан эффективный численный алгоритм и доказана его сходимость.

Приведенная схема приводит к минимаксному решению, если модель наблюдения является регулярной (т.е. все допустимые ковариации вектора наблюдений представляют собой невырожденные матрицы) [8–11]. В сингулярном случае показано, что оценка, минимизирующая среднеквадратическую погрешность при наихудшей ковариации, может не быть минимаксной.

Для построения минимаксной оценки в сингулярных моделях наблюдения развит подход, основанный на методе регуляризации А.Н. Тихонова. Показано, что если применить разработанный метод 1)–4) к регуляризованной модели, то при стремлении параметра регуляризации к нулю найденные оценки сходятся к решению задачи минимаксного оценивания в исходной сингулярной модели [12].

В докладе обсуждается также результат о линейности оценок, минимаксных на классе всех измеримых преобразований. Если модель наблюдения не содержит ограниченных неопределенных параметров, то минимаксной оценкой будет линейная, а наименее благоприятным распределением случайных параметров — гауссовское [13].

Кроме того, в докладе приводится постановка и решение задачи минимаксного оценивания в бесконечномерной неопределенно-стохастической модели [14, 15].

В заключение указаны направления дальнейших исследований и сформулированы открытые проблемы.

Литература

1. Алберт А. Регрессия, псевдоинверсия и рекуррентное оценивание. — М.: Наука, 1977.
2. Пытьев Ю.П. Методы анализа и интерпретации данных. — Изд-во: МГУ, 1990.
3. Verdu S., Poor H.V. Minimax linear observers and regulators for stochastic systems with uncertain second order statistics // IEEE Trans. Autom. Contr. 1984. V.29. No.6. P. 499–511.
4. Куржанский А.Б. Управление и оценивание в условиях неопределенности. — М.: Наука, 1977.
5. Wald A. Statistical Decision Functions. — New York: Wiley, 1950.
6. Vandelinde V.D. Robust properties of solutions to linear-quadratic

- estimation and control problems // IEEE Trans. Autom. Contr. 1977. V.22. No.1. P.138–139.
7. Соловьев В.Н. Двойственные экстремальные задачи и их применение к задачам минимаксного оценивания // Успехи мат. наук. 1997. Т.52. № 4. С. 49–86.
 8. Панков А.Р., Семенихин К.В. Минимаксная идентификация неопределенно-стохастической линейной модели // Автоматика и телемеханика. 1998. № 11. С. 158–171.
 9. Панков А.Р., Семенихин К.В. Методы параметрической идентификации многомерных линейных моделей в условиях априорной неопределенности // Автоматика и телемеханика. 2000. № 5. С. 76–92.
 10. Панков А.Р., Платонов Е.Н., Семенихин К.В. Минимаксная оптимизация инвестиционного портфеля по квантильному критерию // Автоматика и телемеханика. 2003. № 7. С. 117–133.
 11. Панков А.Р., Попов А.С. О проблеме линейного стохастического программирования с вероятностным критерием в условиях неопределенности // Изв. РАН. Сер. Теория и системы управления. 2005. № 1. С. 32–39.
 12. Панков А.Р., Семенихин К.В. О минимаксном оценивании в сингулярных неопределенно-стохастических моделях // Автоматика и телемеханика. 2002. № 9. С. 40–57.
 13. Семенихин К.В. Оптимальность линейных алгоритмов оценивания в задаче минимаксной идентификации // Автоматика и телемеханика. 2004. № 3. С. 148–158.
 14. Борисов А.В., Панков А.Р. Минимаксное линейное оценивание в обобщенных неопределенно-стохастических системах. I. Оценивание случайных элементов со значениями в гильбертовых пространствах // Автоматика и телемеханика. 1998. № 5. С. 102–111.
 15. Семенихин К.В. Минимаксное оценивание случайных элементов по среднеквадратическому критерию // Известия РАН. Сер. Теория и системы управления. 2003. № 5. С. 12–25.

Быстрый непараметрический алгоритм кластеризации многоспектральных изображений

И.А. Пестунов, Ю.Н. Синявский

(Новосибирск)

Введение

Характерной особенностью задач классификации изображений является отсутствие какой-либо априорной информации о количестве и вероятностных характеристиках классов, а также классифицированной обучающей выборки (КОВ). В этих условиях для анализа изображений целесообразно использовать алгоритмы кластеризации, базирующиеся на

400

непараметрическом подходе [1]. В настоящее время в рамках этого подхода разработано достаточно много алгоритмов [2, 3], однако область их применения ограничена в силу больших вычислительных затрат и (или) сложности процедуры настройки основных параметров.

Предлагаемый в докладе алгоритм опирается на введение клеточной структуры данных в пространстве спектральных признаков и реализованную на ее основе итеративную процедуру «среднего сдвига».

Описание метода

Считаем, что каждый вектор $x^{(i)}$ – реализация k -мерного случайного вектора \mathbf{x} , плотность распределения которого $f(x), x \in R^k$, неизвестна и нет какой-либо априорной информации о ее параметрическом виде. В этих условиях для оценивания плотности $f(x)$ в точке $x \in R^k$ целесообразно воспользоваться непараметрической парzenовской оценкой $\hat{f}_N(x)$, определяемой выражением

$$\hat{f}_N(x) = \frac{1}{Nh^k} \sum_{i=1}^N \Phi\left(\frac{x-x^{(i)}}{h}\right),$$

где $\Phi(x)$ – скалярная функция (ядро).

Пусть $m_h(x) = \frac{1}{n_x} \sum_{x^{(i)} \in S_h(x)} x^{(i)}$ – выборочное среднее в точке $x \in R^k$.

Здесь $S_h(x)$ – гипершар с центром в точке x и радиусом h , а n_x – количество точек множества X , содержащихся в $S_h(x)$. Тогда согласно [4], разность $m_h(x) - x$ есть вектор среднего сдвига.

Повторяющиеся движения от точки $x \in R^k$ к ее выборочному среднему $x_1 = m_h(x)$, затем от x_1 к $m_h(x_1)$ и т.д. до некоторого шага n , на котором значение $m_h(x_n)$ будет равно x_n , называют алгоритмом «среднего сдвига». Этот алгоритм представляет собой адаптивную процедуру наискорейшего нахождения локальных мод плотности $f(x)$.

Процедура «среднего сдвига» порождает естественное разбиение множества X на классы: точки $x^{(i)}$ и $x^{(j)}$ принадлежат к одному классу, если итеративные процессы «среднего сдвига», начинающиеся с этих точек, сходятся к одной и той же моде [4].

В докладе предложен алгоритм кластеризации, в котором процедура «среднего сдвига» применяется не ко всем точкам исходного множества X , а к «центрам тяжести» клеток. Этот прием позволяет увеличить объем обрабатываемых данных до нескольких сотен тысяч элементов.

Описание алгоритма

Алгоритм можно записать в виде следующей последовательности шагов.

1. *Формирование клеточной структуры данных в пространстве признаков.* Разбиваем все пространство значений признаков на гиперкубические клетки со стороной $2h$. Вводим общую нумерацию клеток (последовательно от одного слоя к другому) и с каждой клеткой связываем набор попавших в нее векторов из X .

2. *Формирование таблицы «весов» векторов множества X .* Здесь под «весом» вектора x понимаем число вхождений x в множество X .

3. *Формирование множества начальных (стартовых) векторов S для запуска процедуры среднего сдвига.* Для каждой клетки, которая содержит более N_{\min} векторов из X , вычисляем вектор средних значений по всем точкам, попавшим в эту клетку. Совокупность полученных таким образом средних векторов образуют множество S .

4. *Оценивание локальных мод плотности $f(x)$.* Применяем процедуру «среднего сдвига», используя в качестве стартовых векторов элементы множества S . В результате применения процедуры получаем множество локальных мод $Z_0 = \{z_1, \dots, z_{M_0}\}$.

5. *Распределение точек множества X по классам.* Используя метод ближайшего соседа, а в качестве обучающей выборки размеченное множество Z_0 , распределяем множество X по классам.

6. *Формирование множества кандидатов в центры классов.* Определяем на множестве Z_0 все подмножества близких друг к другу точек (точка близка к подмножеству, если она находится на расстоянии не больше h от некоторой точки этого подмножества). Для каждого выделенного подмножества вычисляем его вектор средних значений. Совокупность таких векторов и будет образовывать множество Z_1 .

7. *Нахождение множества центров классов Z .* Вдоль линии L , соединяющей точки z_i и z_j из Z_1 (начиная с точки с меньшей плотностью), с шагом h вычисляем оценку плотности $\hat{f}_N(x)$. Если для

некоторой точки x_m линии L выполнено:

$$\frac{\max[\hat{f}_N(x_1), \dots, \hat{f}_N(x_{m-1})]}{\hat{f}_N(x_m)} > T,$$

где $\hat{f}_N(x_1) = \min[\hat{f}_N(z_i), \hat{f}_N(z_j)]$, а T – заданный порог, то констатируем обнаружение «оврага». Иначе считаем, что z_i и z_j связаны. Назовем максимальное связное подмножество компонентой связности.

На заключительном этапе разбиваем множество Z_1 на компоненты связности. В каждой выделенной компоненте связности находим элемент с наибольшей плотностью и добавляем его к Z .

В докладе приводятся результаты экспериментального исследования алгоритма на модельных данных и реальных изображениях.

Заключение

Представленный в работе алгоритм кластеризации изображений не требует никакой априорной информации, обеспечивая при этом высокое качество результатов. При проведении кластеризации от пользователя требуются минимальные усилия, связанные с настройкой параметров.

Быстродействие алгоритма позволяет работать в диалоговом режиме.

Литература

1. Фукунага К. Введение в статистическую теорию распознавания образов // М.: Наука, 1979. С. 176-205.
2. Halkidi M., Batistakis Y., Vaziannis M. On Clustering Validation Techniques
http://forum.gfk.ru/texts/methods/validity_survey.pdf
3. Comaniciu D., Meer P. Distribution free decomposition of multivariate data // Pattern Anal. and Applications. 1999. N 2. P. 22-30.
4. Cheng Y. Mean shift, mode seeking, and clustering // IEEE Tans. Pattern Anal. Machine Intell. 1995. Vol. 17. P. 790-799.

CFML: язык описания многостраничных структурированных документов для их идентификации и распознавания

В.В. Постников, А.Е. Марченко
(Москва)

Введение

Задачи распознавания структурированных документов являются активно развивающимся направлением в области машинного распознавания текстов.

Ключевой фазой распознавания структурированных документов является фаза сегментации и привязки структуры к образу документа.

Современная печатная продукция отличается широчайшим разнообразием подходов к структуризации документа. Задачи структурной привязки тех или иных узких классов документов решаются давно и достаточно успешно. Каждая система оставляет какой-то набор изначально заданных ограничений на распознаваемые документы, определяя классы документов, с которыми она работает.

Существующие подходы к структурной привязке документа

Рассмотрим несколько общих подходов к описанию структуры машинночитаемых документов.

Формы жесткой геометрии, т.е. формы, структурные элементы которых заданы своими точными координатами в системе координат листа, очевидно, наиболее просты для структурной привязки. Однако функциональность систем распознавания таких форм ограничена.

Более сложные системы ориентированы на распознавание *табличных форм*, т.е. таких форм, структурные элементы которых можно выделить, последовательным делением формы линиями попеременно по горизонтали и вертикали. Практика показала эффективность алгоритмов машинного распознавания форм, заданных таким способом [2].

Дальнейшие усовершенствования методики табличного разбора привели к модели задания форм *геометрическими отношениями*.

Под геометрическими отношениями понимаются простейшие предложения типа «Элемент А лежит выше элемента Б» и т.п. Такая форма описания документа оказывается значительно гибче табличной. Были разработаны алгоритмы распознавания таких форм [1].

Вышерассмотренные алгоритмы объединяет геометрический подход к задаче описания и распознавания форм. Однако структура ряда классов документов плохо поддается описанию в геометрических терминах. Этому препятствуют следующие особенности оформления, часто встречающиеся в документах.

- **Многостраничность с перетеканием.** Существующие системы

работают с многостраничными формами, имеющими жесткое разбиение на страницы, т.е. работают, по сути, с комплектами одностраничных форм. Формы со свободным межстраничным перетеканием структурных элементов для нынешних систем представляют проблему.

- **Альтернативные варианты форматирования и интерпретации данных.** Во многих формах расположение, форматирование и синтаксис элементов может варьироваться. Существующие системы в лучшем случае позволяют задать несколько альтернативных форм, не предоставляя возможности альтернативности внутри форм.
- **Переменный состав полей.** Логическая структура форм часто выходит за пределы простой теговой структуры. Существующие системы работают только с «плоскими» моделями данных, не допускающими вложенных массивов или вариантных определений структур.

Язык CFML

Для разрешения вышеперечисленных проблем необходима система, основанная на принципиально новом подходе к описанию структуры форм. В качестве такого подхода предлагается новый язык описания форм — **CFML** (*Cognitive Forms Markup Language*).

Язык основывается на иерархической схеме описания документа. Каждый элемент иерархии представляет структурный элемент документа, а ниже по иерархии идет описание внутренней структуры этого элемента. Каждый элемент может иметь определенные атрибуты (шрифт, стиль выравнивания, число строк и т.п.).

К основным синтаксическим конструкциям языка, в первую очередь, относятся конструкции, задающие общую структуру формы.

section (секция) — ключевая конструкция иерархии. Задаёт любой связный участок документа из целого числа строк. Играет роль составного оператора. Каждая секция имеет уникальное название, может быть описана отдельно и позволяет ссылаться на себя из любой точки документа.

paragraph (абзац) — представляет отдельный абзац текста.

switch — оператор альтернативы. Задаёт несколько вариантных описаний для области документа. Может использоваться для задания альтернативных вариантов форматирования или набора полей.

loop — оператор цикла. Указывает на возможность повторения конструкции. Каждый цикл имеет имя.

column — многоколоночный текст. Задаёт текст, оформленный в несколько колонок.

Прочие конструкции языка представляют собой собственно элементы формы, т.е. ее «наполнение».

hgap (горизонтальный просвет) — просвет, разделяющий абзацы, секции и т.п.

space (пробел) — основной внутрискочный разделитель.

hline (горизонтальная линия) — разделитель, подобный **hgap**.

vline (вертикальная линия) — разделитель, подобный **space**.

label (метка) — статический текст.

FIELD (поле) — вариантный текст, отгружаемый впоследствии в базу.

Ниже приведен пример текста на CFML, описывающего научную статью.

```
// Определение стиля «список авторов»
style stAuthors ...
// Определение элемента документа «глава статьи»
section Chapter ...
// Определение элемента документа «список литературы»
section References ...
// Определение документа «статья»
section ScientificArticle
  paragraph style=stTitle lines=[1,4] // абзац от 1
                                       // до 4 строк
      FIELD Title
  hgap height=[20,80] // Высота просвета —
                     // от 20 до 80
  paragraph style=stAuthors lines=[1,4]
      FIELD Authors
  hgap height=[20,80]
  column count=[2,3] // от 2 до 3 колонок
  // Chapters — имя цикла,
  // iChapter — переменная цикла,
  // [1, ∞) — допустимые пределы повтора
  loop Chapters index iChapter in [1,∞)
    call section Chapter // Ссылка на
                        // вышеобъявленную секцию Chapter
  hgap
```

Конструкции типа **[n, m]** обозначают числовой отрезок от **m** до **n**.

Структурная вложенность (иерархия) задается в тексте отступами (символами табуляции).

Символы **//** обозначают комментарий, идущий до конца строки.

Язык CFML может служить основой для создания новых эффективных систем распознавания сложных документов.

Литература

1. Постников В.В., Марченко А.Е., Шоломов Д.Л. Разбор структурированного документа в модели с нечеткой логикой. // В сб. «Документооборот. Концепции и инструментарий». М.: УРСС, 2004.

2. Postnikov V.V., Sholomov D.L., Marchenko A.E. FlexiDocs: The Template Driven Document Recognition Technology. // Proceedings of the 6th German-Russian Workshop on Pattern Recognition and Image Understanding (OGRW-6), 2003.

Объекты с собственной структурой в СУБД Oracle и в стандартном SQL

В.В. Пржиялковский

(Москва)

Реляционная модель данных, предложенная более 30 лет назад, вскоре после появления дала начало двум важным для системы управления базами данных (СУБД) явлениям: языку запросов SQL и диалектам SQL, исполненным в основных современных универсальных СУБД. От реляционной модели SQL, а от SQL – диалекты этого языка унаследовали правило скалярности атрибутов таблиц. Согласно этому правилу значения в полях таблицах SQL могут быть только скалярами, о возможной структуре которых SQL ничего не известно, и которые можно занести в БД, обновить или удалить только целиком, а не частями.

Тем не менее, в 90-х годах были предприняты попытки включить возможности работы со сложно устроенными структурами в SQL. В результате они появились в стандарте SQL:1999, а во второй половине 90-х и в диалектах SQL основных поставщиков универсальных СУБД. Здесь эти возможности рассмотрены на примере СУБД Oracle, диалект SQL которой наиболее функционален на фоне прочих СУБД.

Для хранения сложно устроенных данных Oracle предлагает несколько разных средств: большие неструктурированные объекты, объекты с явно заданной структурой и коллекции.

Большие неструктурированные объекты

Большие неструктурированные объекты (large objects, LOBs) являются расширением понятий «строка символов» и «строка байтов», но позволяют работать со строками особо больших размеров. В стандарте SQL:1999 предусмотрено два типа для таких данных: CLOB (character large object) и BLOB (binary large object); Oracle их предлагает четыре: CLOB, BLOB, NCLOB, BFILE. Типы CLOB и NCLOB позволяют хранить тексты, а BLOB и BFILE – последовательность байтов, то есть файл: в первом случае в БД, а во втором вне (и слово «хранить» здесь требует кавычек). NCLOB используется для хранения строк символов в многобайтовой кодировке, например, Unicode.

Все типы категории LOB способны хранить в поле таблицы БД Oracle до 4 Гб данных. Сама СУБД ничего не знает о прикладном назначении таких полей, не накладывает на содержимое никаких ограничений, и, соответственно, не несет за него никакой ответственности.

«Неструктурированы» эти типы именно с точки зрения SQL, а с точки зрения приложения у объектов этих типов может иметься структура, какая требуется. Хранить в таком поле можно все, что угодно: документ в формате Word или PDF, изображение, массив данных и так далее.

На уровне SQL (то есть общения с БД) возможности такого поля ограничены практически только извлечением и присваиванием. Формирование же и интерпретация таких полей почти исключительно выполняется приложением.

Объекты с заданной структурой

Понятие структурированного объекта появилось в стандарте SQL:1999, а в Oracle – в конце 90-х годов, но в собственной реализации. Сама реализация объектных возможностей в Oracle выполнена достаточно качественно и полнофункционально, так что претензии, которые к ней можно было бы предъявлять, вызваны скорее общими проблемами применения объектного подхода в базах данных.

Для работы со структурированными объектами Oracle требует сначала создать тип:

```
CREATE TYPE point_type AS OBJECT ( x NUMBER, y NUMBER );
```

В соответствии с объектной терминологией X и Y называются свойствами объектов этого типа.

Созданный тип, во-первых, позволяет создать таблицы объектов, например:

```
[A] CREATE TABLE point OF point_type;
```

Хотя Oracle, вслед за стандартом SQL, использует термин «таблица», эта таблица специфическая: у нее всегда имеется ровно один, не скалярный атрибут. Тем самым фактически в [A] описывается множество объектов (можно вспомнить, что в таблицах SQL, а вслед и в Oracle, строки образуют [неупорядоченные] множества).

Во-вторых, тип объекта можно использовать для организации не скалярного атрибута в обычной таблице:

```
[Б] CREATE TABLE position (datetime TIMESTAMP, point point_type);
```

С точки зрения моделирования разница между использованием типа объекта в [A] и [Б] в том, что первом случае в базе заводится самостоятельный объект (экземпляр типа), полноценный с позиции объектно-ориентированного подхода. В случае же [Б] речь идет об «объектном атрибуте» традиционной таблицы. В случае [A] объекты, создаваемые в таблице POINT, имеют собственный «идентификатор объекта» (термин объектного моделирования), вследствие чего на них можно ссылаться из других таблиц; в случае же [Б] ничего подобного нет, а адресоваться к свойствам объекта можно только найдя соответствующую строку обычными средствами SQL.

Свойствами объектов могут быть не обязательно «простые» скаляры,

но и неструктурированные объекты LOB и даже структурированные объекты (представленные как «объектные атрибуты»).

Oracle позволяет описывать в типе объектов методы с помощью языков PL/SQL, Java и C. Две разновидности методов в Oracle представляют особый интерес. Во-первых, конструкторы (хотя они формально и не называются методами). Конструкторы можно использовать в выражениях SQL для обозначения «буквальных значений» объектов. Использовать же выражения можно в разных контекстах, например при добавлении новых значений в базу данных или при изменениях. Во-вторых, для каждого типа объекта в Oracle можно альтернативно задать либо специальный метод, задающий правило упорядочения, либо метод, задающий отображение объектов на числовую ось. Существование у типа объектов метода упорядочения или метода отображения на числовую ось позволяет использовать в выражениях SQL не только сравнение объектов на равенство, но и на неравенство.

Oracle полностью поддерживает одиночное наследование типов, с возможностями наследования свойств и методов, переопределения методов, создания абстрактных (бесплодных) подтипов. Допускается переопределение существующего типа при наличии подтипов и супертипов и даже при наличии объектов этих типов в базе, но не всегда, или это не всегда просто. Эти ограничения почти целиком вызваны общими ограничениями объектно-ориентированного подхода к базам данных.

Массивы данных

Стандарт SQL:1999 вводит понятие массива данных, однако Oracle не следует ему буквально и предлагает в своем диалекте языка две разновидности коллекций: вложенные таблицы и массивы VARRAY. Основная потребительская разница между типами вложенной таблицы и массива VARRAY в том, что первый применяется для моделирования в базе данных неупорядоченного множества, а второй – для моделирования списков.

В СУБД Oracle массивы могут состоять не только из скаляров или структурированных объектов, но даже из ссылок на объекты в БД, то есть быть именно коллекциями в понимании автора реляционной модели данных Э. Кодда.

Oracle дает разнообразные возможности работать с массивами на уровне элементов программно, средствами PL/SQL, но целый ряд действий допускается и в SQL.

Работа поддержана грантом РФФИ 04-01-00401-а.

Распознавание изображений при помощи алгоритма поиска оптимального вложения графа

А.В. Пролубников

(Омск)

Задача нахождения в множестве графов графа ближайшего к данному
Рассматривается задача со следующей постановкой. Дано множество взвешенных неориентированных попарно неизоморфных графов $\{G_1, \dots, G_N\}$. Граф G является модификацией некоторого графа из этого множества, полученной изменением весов его ребер. $V(G)$ и $E(G)$ – множества вершин и ребер графа G . $|V(G)| = |V(G_i)| = n$, $i = \overline{1, n}$. Требуется найти k такое, что граф G наиболее близок к G_k в смысле некоторого вводимого расстояния между графами.

В качестве расстояния между графами рассматривается функция $ED_0(G_A, G_B) = \min F(A^\varphi - B)$, где F – евклидова (фробениусова) норма матрицы, A, B – модифицированные матрицы смежности графов G_A и G_B , A^φ – матрица, получаемая из A перестановкой ее строк соединенной с такой же перестановкой ее столбцов, задаваемой биекцией (вложением графа) $\varphi: V(G_A) \rightarrow V(G_B)$. В определении ED_0 минимум берется по всем таким отображениям. Модифицированные матрицы смежности графов представляют собой матрицы смежности с измененной, ненулевой диагональю и являются положительно определенными, что позволяет решать связанные с ними системы линейных алгебраических уравнений. Если графы изоморфны, то существует изоморфизм φ , для которого $F(A^\varphi - B) = 0$. Если графы не изоморфны и φ дает минимум F , то при данном вложении одного графа в другой несовпадение ребер будет минимальным.

Алгоритм поиска оптимального вложения графа

Для поиска G_k ближайшего к G в смысле введенного расстояния ED_0 используется алгоритм нахождения приближенного решения задачи поиска оптимального вложения графа, являющийся модификацией алгоритма спектрального расщепления проверки изоморфизма графов [1]. В задаче поиска оптимального вложения графа G_A в граф G_B требуется найти биекцию φ_0 дающую $ED_0(G_A, G_B)$. Задача поиска

оптимального вложения графа является частным случаем задачи проверки на изоморфизм одного графа подграфу второго, получаемым введением дополнительного ограничения $|V_A| = |V_B|$, оставляющем задачу NP -полной [2].

Пусть G_A и G_B изоморфны, $A^0 = A$, $B^0 = B$, и на j -й итерации алгоритма граф представляется матрицей $A^j = A^{j-1} + \varepsilon_j E^k$, где A^{j-1} – матрица, используемая на предыдущей итерации, E^k – матрица с единственным ненулевым элементом, равным 1, находящимся в ее k -й диагональной позиции, $1 \leq k \leq n$. Если φ_0 – изоморфизм, то

$$B^j = B^{j-1} + \varepsilon_j E^{\varphi_0(j)} \Leftrightarrow B^j = (A^j)^{\varphi_0} \Leftrightarrow (B^j)^{-1} = ((A^j)^{-1})^{\varphi_0}.$$

Если φ_0 – оптимальное вложение, а G_A и G_B , вообще говоря, неизоморфны, то

$$B^j = B^{j-1} + \varepsilon_j E^{\varphi_0(j)} \Leftrightarrow F((A^j)^{\varphi_0} - B^j) = \min F((A^j)^{\varphi} - B^j).$$

Несложно показать, что

$$\begin{aligned} F((A^j)^{\varphi_0} - B^j) &= \min F((A^j)^{\varphi} - B^j) \Leftrightarrow \\ \Leftrightarrow F(((A^j)^{\varphi_0})^{-1} - (B^j)^{-1}) &= \min F(((A^j)^{\varphi})^{-1} - (B^j)^{-1}). \end{aligned}$$

На итерациях алгоритма в качестве основной эвристики используются решения систем линейных уравнений, связанных с матрицами графов а также их изменения при производимых возмущениях. В случае близости откликов компонент решений на возмущения устанавливается соответствие между вершинами графов. Если $ED_0(G_A, G_B)$ мало и выполняется $F(A^{\varphi} - B) / F(B) \leq \theta$, где $\theta \leq 1 / \mu(A)$, то разница в нормах решений систем линейных уравнений, связываемых с G_A и G_B , при малых θ мала и линейно зависит от θ ([3]), что позволяет находить близкое к оптимальному вложение одного графа в другой. Число обусловленности μ матриц, представляющих графы, на протяжении всей работы алгоритма не превышает 4, что позволяет решать системы линейных уравнений с заданной точностью при заданной на старте алгоритма длине мантиссы машинных чисел. Требуемое для решения систем линейных уравнений количество машинных операций составляет

$O(n^2)$. Дополнительные эвристики, используемые в ходе работы алгоритма для уточнения выбора вершин при установлении соответствия между ними, вычисляются за число элементарных машинных операций, оцениваемое как $O(n^2)$. Общая трудоемкость алгоритма составляет $O(n^4)$.

**Распознавание изображений при помощи алгоритма
поиска оптимального вложения графа**

Алгоритм поиска оптимального вложения графа применяется к задаче со следующей постановкой. Имеется изображение S и набор эталонных изображений $\{S_1, \dots, S_N\}$. Предполагается, что S является модификацией одного из эталонных изображений, полученной изменением параметров его пикселей. Требуется определить, модификацией какого изображения из $\{S_1, \dots, S_N\}$ является изображение S .

Пусть G, G_i – графы, соответствующие S, S_i . Алгоритм поиска оптимального вложения графа используется для сравнения G на близость с графами $\{G_1, \dots, G_N\}$ и вычислением $F(A^{\varphi_i} - A_i)$, где φ_i – вложение G в G_i , найденное алгоритмом. S ставится в соответствие эталонное изображение S_{i_0} ,

$$\text{если } F(A^{\varphi_{i_0}} - A_{i_0}) = \min_{1 \leq i \leq n} F(A^{\varphi_i} - A_i).$$

Смещение и поворот изображения относительно левого верхнего угла прямоугольного окна, в котором содержится распознаваемое изображение, не влияют на успешность распознавания изображения при помощи предлагаемого алгоритма. Устойчивого распознавания изображения можно добиться в том случае, если модификация эталонного изображения, заключающаяся в изменении параметров его пикселей, приводит к изменению веса до 30% ребер графа изображения, и изменение веса ребра составляет в среднем до 10% от исходного веса ребра.

Литература

1. Пролубников А.В., Файзуллин Р.Т. Алгоритм спектрального расщепления проверки изоморфизма графов и его приложения // Математические методы распознавания образов. Доклады 11-й Всероссийской конференции. Москва, 2003. С. 162-164.

2. Гэри М., Джонсон Д. Вычислительные машины и труднорешаемые задачи. М.: Мир, 1982.
3. Годунов С.К. и др. Гарантированная точность решения систем линейных уравнений в евклидовых пространствах. Новосибирск: Наука, 1988.

Защита передачи видеоданных на основе применения алгоритмов проверки изоморфизма графов

А.В. Пролубников, Г.С. Ржаницын, Р.Т. Файзуллин

(Омск)

Системы видеоконференций – мощное средство повышения эффективности деловых контактов. Если учесть, что в настоящее время вычислительная мощность пользовательских компьютеров и пропускная способность сетей позволяет осуществлять обработку и передачу видеоданных, а устройства видеосъемки класса web-камер являются достаточно дешевыми, подобные разработки являются востребованными. Естественным образом встает вопрос о защите конфиденциальности информации. Традиционно возможны два варианта защиты – на канальном уровне и на уровне представления или приложения. Защита на канальном уровне обычно осуществляется с помощью аппаратных устройств, они являются достаточно дорогими, нуждаются в обслуживании, но позволяют защищать полностью весь сетевой трафик. Широко распространенный подход к шифрованию видеоданных на уровне приложения, приемлемый для сохранения качества изображения и требований быстродействия заключается в перестановке строк или столбцов кадров видеоизображения [1]. Необходимо отметить, что такой шифр нельзя назвать стойким. Нами был произведен ряд экспериментов по восстановлению изображений, зашифрованных подобными методами. На рисунках 1 и 2 показан пример такого восстановления.




Рис. 1. Зашифрованное изображение. Рис. 2. Восстановленное изображение.

Здесь в качестве критерия для отбора строк выбрана мера близости,

основанная на метрике $d(a_i, a_j) = \sum_{k=1}^m |a_{i,k} - a_{j,k}|$, где A – матрица,

соответствующая изображению. Оказалось, что в данной метрике практически не возникает коллизий, и исходное изображение легко восстанавливается, аналогично тому, как восстанавливается текст по анализу биграмм и триграмм [2]. Трудоемкость восстановления оценивается как $O(n^3)$.

Исходя из этого, представляется перспективным использовать для защиты видеоданных шифр двойной перестановки, то есть соединение перестановки строк с перестановкой столбцов. Кроме того, поскольку процедура дешифрования шифра двойной перестановки может быть сведена к решению задачи проверки изоморфизма графов [3], можно использовать алгоритмы её решения для построения криптосистемы, реализующей защищенный видеоканал. Особенностью этой криптосистемы является неявная передача ключа к шифру. То есть ключ шифрования динамически изменяется в процессе передачи и является результатом решения задачи проверки изоморфизма для соответствующих графов.

Если пикселям нешифрованного изображения соответствует матрица C , то шифру двойной перестановки изображения будет соответствовать матрица $C' = P_1 * C * P_2^T$, где P_1, P_2 – матрицы перестановок, реализующие перестановку строк (P_1) и перестановку столбцов (P_2) матрицы C . Будем далее в тексте обозначать перестановки и соответствующие им матрицы одинаково. Построим по C матрицу C_2 , а

$$\text{по } C' \text{ - матрицу } C'_2: C_2 = \begin{pmatrix} 0 & C \\ C^T & 0 \end{pmatrix}, C'_2 = \begin{pmatrix} 0 & C' \\ C'^T & 0 \end{pmatrix}$$

Матрицы C_2 и C'_2 – симметрические матрицы. Они могут рассматриваться как матрицы смежности некоторых взвешенных неориентированных двудольных графов. Таким образом, если один кадр является шифром двойной перестановки другого, то соответствующие им графы – графы с матрицами смежности C_2 и C'_2 -изоморфные графы. Изоморфизм графов, задаваемый матрицей перестановки P задает перестановку строк и столбцов пикселей изображения перестановки P_1 и P_2 . То есть дешифрование шифра двойной перестановки равносильно решению задачи проверки изоморфизма взвешенных неориентированных графов.

Для решения задачи проверки изоморфизма используем метод

спектрального расщепления, описанный в [3]. Чтобы его использование было вычислительно эффективно, необходимо, чтобы графы обладали свойством тривиальности группы автоморфизмов [4].

Построение криптосистемы

1. Пусть абоненты обладают набором одинаковых изображений, таких, что соответствующие им графы обладают тривиальной группой автоморфизмов.
2. Абоненты выбирают одно из изображений с помощью какого-либо протокола с нулевым разглашением.
3. Один из абонентов применяет случайную двойную перестановку к выбранному изображению и рассылает ее всем остальным.
4. Абонент, получивший изображение, подвергнутое перестановке, зная какое изображение было выбрано на шаге 2, ставит задачу проверки изоморфизма и вычисляет перестановку.
5. Полученная двойная перестановка объявляется текущим ключом.

Для демонстрации возможностей была разработана программа, реализующая все вышеизложенное. Она позволяет как вести диалог нескольким абонентам, так и осуществлять трансляцию одного видеоизображения нескольким клиентам. Из ее особенностей можно отметить, что вместо набора изображений у абонентов имеется алгоритм их генерации. Протокол выбора изображений (параметров алгоритма генерации) построен на базе протокола конференц-связи, описанного в [5].

Литература

1. Володин А.А., Митько В.Г., Спинко Е.Н. Обработка видео в системах телевизионного наблюдения // Вопросы защиты информации. М.: 2002. С. 34-47.
2. Алферов А.А., Зубков А.Ю., Кузьмин А.С., Черемушкин А.В. Основы криптографии – М: Гелиос АРВ, 2001.
3. Faizullin R., Prolubnikov A. An Algorithm of the Spectral Splitting For The Double Permutation Cipher // Pattern Recogniton and Image Analysis. MAIK, Nauka. Vol. 12, p. 365-375. No. 4, 2002.
4. Пролубников А.В., Файзуллин Р.Т. Класс графов, задача проверки изоморфизма для которых разрешима за полиномиальное время алгоритмом спектрального расщепления // Математические структуры и моделирование: Сб.научн. тр. Под ред. А.К.Гуца. Омск: Омск. гос. университет, 2003. Вып. 11. С.28-57.
5. Burmester M. Desmedt Y. A secure and efficient conference key distribution system // Advanced in Cryptology – EUROCRYPT'89. LNCS 434. – 1990. – pp. 122 – 133.

Морфологический анализ изображений: итоги и перспективы

Ю.П. Пытьев, А.И. Чуличков
(Москва)

Введение

Морфологический подход к анализу изображений был предложен на физическом факультете МГУ им.М.В.Ломоносова в 70-х годах XX века. Под морфологическим анализом понимаются методы решения задач узнавания, классификации объектов, выделения отличий в сценах по их изображениям, оценивания параметров объекта по его изображению, основанные на исследовании математических моделей изображений. Так как на практике некоторые детали модели, связывающей объект с его изображением, как правило, неизвестны, (например, условия освещения, оптические свойства поверхностей объекта, характеристики системы формирования изображения), то можно указать лишь множество изображений, порожденное данной сценой при всех возможных параметрах модели формирования изображений. Это множество изображений и называется его формой. Если это множество выпукло и замкнуто в нормированном пространстве всех изображений, а расстояние между изображениями – сильно выпуклая функция, то с формой изображения сцены можно однозначно связать проектор на это множество. В терминах этих проекторов конструктивно решаются названные задачи анализа изображений [1-3].

Математическая модель изображения. Форма изображения

Под изображением будем понимать числовую или векторную функцию $f(\cdot)$, заданную на ограниченной области X плоскости R_2 ; множество всех изображений образует линейное нормированное функциональное пространство. Если $f(\cdot)$ -числовая функция, то $f(x)$, $x \in X$, называется яркостью точки x поля зрения X , для векторнозначной функции направление вектора $f(x)$, $x \in X$, определяет цвет изображения, а его норма – яркость изображения $f(\cdot)$ в точке x поля зрения X . Наибольшее распространение в морфологическом анализе получили евклидово пространство функций с интегрируемым квадратом и пространство функций $C(X)$, непрерывных на элементах конечного разбиения поля зрения X .

Пусть, например, изображение f – элемент класса $L_2(X)$ измеримых и квадратично интегрируемых на X функций, Φ – класс функций, определенных и принимающих значения на действительной

прямой, а F_f – подкласс Φ , выделенный условием:

$$F_f = \{F * f, F \in \Phi, F * f \in L_2(X)\},$$

где $F * f(x) = F(f(x))$, $x \in X$. Формой изображения $f \in L_2(X)$ назовем множество

$$V_f = \{F * f, F \in F_f\},$$

то есть множество всех изображений, яркости которых могут быть получены из яркостей изображения f с помощью преобразований из класса F_f . Тем самым точки поля зрения, имеющие одну и ту же яркость для изображения f , будут иметь одинаковую яркость и для изображения $F * f$. Области поля зрения, имевшие одинаковую яркость для изображения f , в результате преобразования $F \in F_f$, могут объединяться, но не могут распадаться. Тем самым, изображения из класса V_f имеют детальность, эквивалентную или более простую, чем детальность изображения f .

В морфологическом анализе изображений определяется, что форма изображения f' не сложнее, чем форма f , если $f' \in V_f$. Этот факт обозначается следующим образом: $f' \prec f$. Изображения f' и f называются эквивалентными по форме ($f \sim f'$), если $f' \prec f$ и $f \prec f'$.

Если $V_{f'} = V_f$, то f' и f называются совпадающими по форме. Множество функций F_f , определяющее модель изменения яркости изображения f , обычно предполагается выпуклым, а V_f – замкнутым в пространстве $L_2(X)$. При этих условиях существует оператор P_f проецирования на V_f , который определяется как решение задачи наилучшего приближения:

$$\|P_f g - g\|^2 = \inf \{\|f' - g\|^2 \mid f' \in V_f\} \forall g \in L_2(X)$$

Изображение $P_f g$ является наилучшим приближением g изображениями, форма которых не сложнее, чем форма f ; соответственно, изображение $g - P_f g$ представляет все, что отличает g

по форме от f . Поскольку V_f замкнуто, то $V_f = \{g \in L_2, P_f g = g\}$, и оператор P_f полностью определяет форму f . В морфологическом анализе проектор P_f также называют формой изображения f .

Аналогичным образом определяется форма для векторнозначных (цветных) изображений и для изображений из класса $C(X)$.

Задачи, решаемые морфологическими методами

Морфологические методы позволяют анализировать изображения с точки зрения их формы. В частности, если заданы формы V_1, \dots, V_M изображений сцен, то предъявленное изображение g относится к классу V_k , если

$$\frac{\|g - P_k g\|^2}{\|P_0 g - P_k g\|^2} \leq \frac{\|g - P_j g\|^2}{\|P_0 g - P_j g\|^2} \text{ для всех } j = 1, 2, \dots, M; \quad (1)$$

здесь P_j - проектор на V_j , $j = 1, 2, \dots, M$, P_0 - проектор на множество изображений, принимающих всюду на X одно и то же значение, [1-3]. Если условию (1) удовлетворяет несколько индексов k_1, \dots, k_m , изображение g относится к любому из классов V_{k_1}, \dots, V_{k_m} .

Морфологическими методами решаются задачи узнавания и классификации объектов, выделения отличий в сценах по форме их изображений, оценивания параметров объекта по его изображению и др.

В последнее время разрабатываются новые методы морфологического анализа, основанные на нелинейных проекторах и теоретико-возможностных моделях [4].

В докладе приводятся и иллюстрируются решения перечисленных выше и некоторых других задач.

Работа выполнена при финансовой поддержке РФФИ, грант № 05-01-00615-а.

Литература

1. Пытьев Ю.П. Морфологический анализ изображений. Докл. АН СССР. - 1983. - Т.269, N 5. - С. 1061-1064.
2. Pyt'ev Yu.P. Morphological Image Analysis. - Pattern Recognition and Image Analysis. V.3. No 1. 1993, pp. 19-28.
3. Пытьев Ю.П. Задачи морфологического анализа изображений. // В сб. «Математические методы анализа природных ресурсов Земли из Космоса». М.:Наука. 1984.

4. Пытьев Ю.П. Возможность. Основы теории и применения. // 2000. Москва: Эдиториал УРСС.

Потенциальная эффективность идентификации заданного фрагмента береговой линии

А.А. Рожнецов

(Йошкар-Ола)

Для широкого круга систем машинного зрения – картографических, навигационных – характерна задача распознавания фрагментов береговой линии рек, озер, морей и т.п. При этом важной задачей является определение предельно достижимого качества распознавания в таких системах и сравнение эффективности предлагаемых алгоритмов обработки с полученными оценками. Поскольку вся информация о форме береговой черты содержится в ее контуре, то для решения данной задачи могут быть использованы результаты определения потенциальной эффективности распознавания контурных комплекснозначных сигналов [1].

Близость полученных характеристик распознавания к потенциально достижимым определяется близостью формы распознаваемых фрагментов к форме контуров, задаваемых симплексными сигналами, обеспечивающих предельно достижимые вероятности правильного распознавания.

Поскольку при обработке контуров береговой черты, как правило, приходится иметь дело с некоторыми фрагментами незамкнутых контуров, то попутно приходится решать задачу определения начальной точки искомого контура на обрабатываемом фрагменте. Поэтому, помимо требований к форме контура с позиций распознавания, можно выдвигать определенные требования и с позиций поиска начальной точки искомого фрагмента. Данные требования могут быть совмещены, при обработке сигналов с АКФ, имеющей равные -1 боковые лепестки. При этом сдвинутые копии сигнала образуют алфавит симплексных сигналов, а максимально достижимая разность между главным и боковыми лепестками обеспечивает необходимое качество поиска начальной точки. Можно показать, что при заданной размерности контура k и норме контура $\|\Gamma\| = \sqrt{k}$ энергетический спектр такого контура, задающего алфавит симплексных сигналов, будет иметь вид:

$$|\rho(m)|^2 = \begin{cases} 1 & \text{при } m = 0, \\ k + 1 & \text{при } m = 1, 2, \dots, k - 1, \end{cases} \quad (1)$$

где $\rho(m)$ – отсчеты спектра контура. Таким образом, задача оценки возможности достижения предельных вероятностей правильного

распознавания сводится к оценке степени близости спектра рассматриваемого контура к значениям, задаваемым соотношением (1). В работе выполнены исследования спектральных характеристик фрагментов контурных линий и показано, что часть фрагментов удовлетворяют выдвинутым требованиям к виду спектра.

Таким образом, в работе рассмотрена возможность достижения предельных вероятностей правильного распознавания контуров береговых линий. Полученные результаты могут учитываться при выборе ориентиров и формировании банков эталонов для максимизации вероятностей правильных решений при обработке изображений данного класса.

Работа выполнена при финансовой поддержке РФФИ, проекты № 04-01-00243, №05-01-96510р_поволжье_a

Литература

1. Фурман Я.А., Роженцов А.А. О предельно достижимых вероятностях правильного распознавания многомерных векторных сигналов// Автометрия, 2004, том 40, № 3, с.31-45.

Потенциальная эффективность распознавания объектов по их форме, задаваемой непрерывным контуром

А.А. Роженцов, Р.Г. Хафизов, Н.А. Добрынская
(Йошкар-Ола)

При обработке контуров изображений одной из помеховых составляющих являются шумы дискретизации. Перспективные системы, базирующиеся на методологии контурного анализа, должны ориентироваться на обработку непрерывных контуров, свободных от данного недостатка [1]. В этой связи возникает вопрос о предельно достижимых характеристиках подобных систем при распознавании изображений.

Как показано в работе [3] для дискретных контуров, данная задача решается путем поиска вероятностей правильного распознавания максимально разнесенных в конечномерном векторном пространстве сигналов в виде симплексных контуров. В общем случае такой подход может оказаться неприемлемым для непрерывных сигналов, поскольку переход к ним означает переход к анализу сигналов в бесконечномерном пространстве. Однако контуры изображений обладают свойством «врожденной» периодичности, поэтому в большинстве случаев их спектр может быть ограничен и сравнение сигналов будет выполняться уже в конечномерном пространстве, размерность которого определяется количеством гармоник в спектре анализируемых сигналов.

Предлагаемый подход к синтезу непрерывных симплексных сигналов базируется на взаимной однозначности получения скалярного произведения сигналов как в спектральной, так и во ременной области,

поскольку скалярное произведение спектральных компонент сигнала с точностью до масштабного множителя равно скалярному произведению сигналов, найденному во временной области. Алгоритм синтеза непрерывных симплексных сигналов, состоит в следующем.

1. Формируется алфавит дискретных симплексных сигналов \mathbf{E} с заданными объемом и размерностью k .

2. Для полученных дискретных симплексных сигналов $\mathbf{E} = \{\mathbf{E}_j\}_{0,k-1}$ вычисляется их спектр $\mathbf{P} = \{\mathbf{P}_j\}_{0,k-1}$.

3. Полученные отсчеты спектра задают веса базисных функций для вычисления обратного преобразования Фурье при формировании непрерывных симплексных сигналов $E = \{\varepsilon_j(t)\}_{0,k-1}$:

$$\varepsilon_j(t) = \sum_{m=-\lfloor k/2 \rfloor}^{\lfloor k/2 \rfloor} \rho_j(m) \exp\left\{i \frac{2\pi}{T} m t\right\}, t \in [0, T[.$$

По аналогии с разностным кодом для дискретных контуров, такое представление будем называть дифференциальным, а по аналогии с суммарным кодом введем также и интегральное представление непрерывных контуров. На рис.1 представлены примеры синтезированных симплексных непрерывных контуров.




Рис.1. Пример формирования алфавита непрерывных симплексных сигналов: а) графическое отображение дифференциального представления непрерывных симплексных сигналов; б) графическое отображение интегрального представления непрерывных симплексных сигналов

Помехоустойчивость полученных непрерывных симплексных сигналов будет соответствовать помехоустойчивости порождающих их дискретных симплексных последовательностей.

Другой подход к синтезу непрерывных симплексных контуров базируется на взаимосвязи между ортогональными и симплексными сигналами, задаваемой соотношением:

$$\varepsilon_m(t) = \gamma_m(t) - \frac{1}{N} \sum_{n=0}^{N-1} \gamma_n(t), \quad m = 0, 1, \dots, N-1,$$

где $\gamma_n(t)$ – набор ортогональных функций, $n = 0, 1, \dots, N-1$, $\varepsilon_m(t)$ – формируемый набор симплексных функций. На рис.2 приведены примеры формирования непрерывных симплексных контуров на базе ортогональных функций вида $\gamma_m(t) = \exp\left\{i \frac{2\pi}{T} mt\right\}$, $t \in [0, T[$ для случая $N = 10$, $m = 1$ и $m = 2$.




Рис.2. Пример формирования алфавита непрерывных симплексных сигналов на основе функций $\gamma_m(t) = \exp\left\{i \frac{2\pi}{T} mt\right\}$: а) графическое отображение дифференциального представления непрерывных симплексных сигналов; б) графическое отображение интегрального представления непрерывных симплексных сигналов

Предложенные в работе подходы к формированию непрерывных симплексных контуров, обеспечивающих потенциальную помехоустойчивость при обработке, позволяют выполнять оценку эффективности систем обработки непрерывных контуров изображений.

Работа выполнена при финансовой поддержке РФФИ, проекты № 04-01-00243, №05-01-96510р_поволжье_а.

Литература

1. Методика обработки непрерывных комплекснозначных сигналов/ Хафизов Р.Г., Добрынская Н.А.; Марийск. гос. техн. ун-т.- Йошкар-Ола, 2005.- 13 с. Деп. В ВИНТИ 06.06.05 № 812-В2005.

2. Смирнов. Methods of the Shaping the Physical Carrier of complex-value Signals// PRIA –7-2004, St.Peterburg, October 18-23, 2004. P540.
3. Фурман Я.А., Роженцов А.А. Potential Recognition Efficiency in the Case When the Sizes of Alphabets Coincide with Dimensions of Vector Signals// Pattern Recognition and Image Analysis, vol.14, №4, p.495-518.

Алгоритмы динамического обучения принятию решений в задаче формирования инвестиционного портфеля

М.Ю. Романов, С.А. Ументаев, А.Е. Кругов, К.В. Воронцов

(Москва)

В последние 10–15 лет многие инвестиционные компании, хэдж-фонды, банки и частные инвесторы переходят на полностью автоматическое управление капиталом. Задача *динамического формирования инвестиционного портфеля* (on-line portfolio selection, PS) заключается в том, чтобы по мере поступления торговых данных автоматически подбирать набор активов (акций, фьючерсов, валют, и т. п.), оптимальный для вложения капитала.

По своей природе задача управления инвестиционным портфелем близка к задачам прогнозирования. В каждый момент времени t становится известно описание ситуации x_t — вектор цен всех рассматриваемых активов. Алгоритм принятия решений по предыстории x_1, \dots, x_t должен выдать решение u_t — вектор долей, в которых капитал распределяется по активам. Качество принятого решения возможно оценить только в следующий момент времени, когда становится известна ситуация x_{t+1} . Задача заключается в том, чтобы построить алгоритм, выдающий решения в среднем приемлемого качества в течение достаточно длительного интервала времени. Критерием качества является либо максимизация суммарной прибыли (спекулятивный портфель), либо обеспечение невысокой, но устойчивой прибыли (нейтральный портфель).

Начиная с конца 50-х годов, когда появилась портфельная теория Марковица [1], усилия исследователей долгое время были сосредоточены на изучении вероятностных моделей PS. К сожалению, даже глубокое понимание свойств стохастических процессов, описывающих биржевую торговлю, оказывается практически бесполезным для регулярного принятия решений. В 90-е годы возникла более прагматичная *сравнительная теория портфелей* (competitive theory of PS), в которой за основу брались конкретные алгоритмы принятия решений, и целью был ответ на вопрос: какой алгоритм лучше? При этом не имеет значения, основан ли алгоритм на какой-либо модели, или это чистая эвристика. Был предложен ряд достаточно удачных алгоритмов: сбалансированный портфель (constant rebalanced portfolio), универсальный портфель, экспоненциальный градиент (EG), DELTA, ANTICOR, и др [2]. Все они

неоднократно тестировались на реальных данных многих бирж, в том числе на 22-летней истории NYSE (New-York Stock Exchange). Однако в конце 90-х американский рынок акций претерпел ряд структурных изменений, и в последующие годы все эти стратегии перешли в разряд убыточных.

В настоящей работе задача PS рассматривается с позиций обучения по прецедентам. Сложность данной задачи, по сравнению со стандартными задачами классификации и прогнозирования, состоит в том, что критерии качества не выражаются в терминах средней ошибки, не дифференцируемы по параметрам и существенно неустойчивы относительно малых изменений параметров. Кроме того, исходные данные — временные ряды цен активов — представляют собой «почти белый шум», на фоне которого едва улавливаются *тренды* — участки более-менее постоянного роста или падения цен. Именно тренды являются основным источником извлечения прибыли при использовании автоматических торговых систем. В этих условиях основной проблемой становится *эффект переобучения*, когда алгоритм неплохо настраивается на исторических данных, но на последующем интервале не обеспечивает требуемого качества.

К настоящему времени сложилось понимание, что качественная автоматическая торговая система должна обладать высочайшим уровнем адаптивности. То есть способностью не только выбирать активы, наиболее прибыльные за последнее время (как это делает алгоритм EG), или наименее коррелированные (как это делают алгоритмы DELTA и ANTICOR, отчасти следуя теории Марковица). Необходим также механизм, обеспечивающий своевременное переключение с одного алгоритма на другой, а в более общем случае — построение адаптивных композиций портфельных алгоритмов. Общая теория и методы синтеза таких композиций глубоко проработаны в алгебраическом подходе к построению корректных процедур обработки информации на основе некорректных эвристических алгоритмов [3].

В докладе рассматривается разработанная авторами система автоматической торговли, обладающая достаточно высокой степенью адаптивности. Система состоит из следующих функциональных блоков.

Technical Analysis. Блок содержит большое число технических индикаторов рынка. Это базовые торговые стратегии, работающие с отдельными активами. Помимо стандартных индикаторов [4], применяются собственные, основанные на поиске логических закономерностей в бинарных временных рядах [5].

Portfolio Selection. В данном блоке реализованы известные алгоритмы EG, ANTICOR, и несколько оригинальных, основанных на отборе активов в портфель с помощью «полужадных» алгоритмов или генетического

поиска.

Risk Management. Реализованы алгоритмы адаптивного блокирования и разблокирования портфельных алгоритмов, основанные на постоянном накоплении данных об их «успешности».

Back Testing. Реализована методика тестирования всей системы на длительных интервалах исторических данных в режиме скользящего контроля. Задача этого блока — контролировать эффект переобучения и формировать структуру портфельных алгоритмов. Разработана инструментальная среда, позволяющая проводить серии вычислительных экспериментов на реальных данных, с возможностью сохранения результатов экспериментов в базе данных.




Рис. 1. График среднерыночной цены и доходности в процентах. Содержит около 160 контрольных интервалов.

Результаты тестирования на реальных данных американских фондовых бирж NYSE и NASDAQ показали, что система способна адаптироваться к рынку и обеспечивать достаточное качество на тех участках, где ни один из известных алгоритмов не даёт стабильных результатов. На Рис 1. показан результат одного из «длинных прогонов»: динамика индекса средней рыночной цены и динамика доходности, даваемой системой. Медленный, но устойчивый рост доходности наблюдается как на восходящем, так и на падающем, и даже на «боковом» рынке.

Литература

1. Markowitz H. Portfolio Selection: Efficient Diversification of Investments. — Wiley, New York, 1959.

2. Borodin A., El-Yaniv R., Gogan V. Can we learn to beat the best stock // Advances in Neural Information Processing Systems 16 / Ed. By S. Thrun, L.Saul, B. Schölkopf. – Cambridge, MA: MIT Press, 2004.
3. Журавлев Ю. И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики. — 1978. — Т. 33. — С. 5–68.
4. Колби Р., Мейерс Т. Энциклопедия технических индикаторов рынка. — Издательский дом «Альпина», 1998.
5. Кругов А. Е. Об одном алгоритме динамического обучения принятию решений в дискретных временных рядах // В настоящем сборнике. 2005.

**Формирование классификационно-ориентирующих баз
экспериментальных данных с применением расширенного
метода линейных направлений - согласующих функций
при изучении функционирования ткацкого станка**
Р.Р. Саакян, И.А. Шпехт, В. А. Климов, И.Н. Верес
(Благовещенск, Санкт - Петербург)

Введение

Требования современного потребительского рынка ставят перед предприятиями текстильной и легкой промышленности задачи разработки и производства качественно новой продукции. Между тем, выход из этого положения можно найти путем модернизации устаревшего оборудования.

Процесс тканеобразования на ткацком станке, представляющий сложную технологическую систему, с точки зрения работы ткацкого станка, сводится к переплетению основных и уточных нитей с образованием тканого полотна и происходит без вмешательства в ее работу человека, за исключением устранения каких-либо неполадок. В процессе формирования нити претерпевают многочисленные деформации и нагрузки. Основная задача ткачества - получение ткани, удовлетворяющей заданным потребительским свойствам.

Теоретически процесс тканеобразования - это детерминированная задача механики, которая поддается однозначному описанию при известных входных параметрах. К входным параметрам относятся параметры исходного сырья, параметры технического состояния станка и параметры настройки станка.

Выходная продукция характеризуется качественными параметрами, к которым относятся размерные показатели, показатели структуры, показатели дефектности и эксплуатационные показатели.

Современное состояние текстильной промышленности требует от текстильных предприятий России значительного вложения средств для

внедрения новых информационных технологий во все сферы деятельности с целью ускорения и повышения качества новых разработок, а также повышения конкурентоспособности российских изделий.

Немаловажную роль в этом играет автоматизация технологических режимов ткацкого производства. Внедрение в процесс ткачество вычислительных машин нового поколения делает реальной возможность использования автоматизированной системы проектирования технологических режимов ткачества не только при проведении научных исследований, но и непосредственно в производстве.

Это значительно уменьшит время на освоение нового ассортимента тканей, позволит избежать многочисленных ошибок при организации его производства.

В настоящее время для решения указанной выше трудноформализуемой задачи тканеобразования все большую популярность получают методы анализа данных, основанные на теории распознавания образов, классификации и идентификации данных.

Постановка задачи

Качество ткани во многом зависит от фактической точности ее выработки на ткацком станке. При одних и тех же стандартах качество продукции будет лучше в тех случаях, когда имеются большие резервы технологической точности.

Для выработки ткани заданного класса характеристик выходной продукции требуется знание многочисленных параметров процесса ее формирования на ткацком станке. При постоянном качестве заправочных нитей, и удовлетворительном состоянии узлов станка, основной задачей является выбор параметров настроек ткацкого станка для обеспечения заданного класса характеристик выходной продукции.

Целью настоящей работы является формирование общей методологии расширения приложений теории распознавания образов применительно к изучению функционирования ткацкого станка; при этом содержание указанного расширения относится ко всем этапам методологии:

- к обработке первоначальной экспериментальной информации при опоре на разработанную информационную ориентирующую схему для малого объема требуемых прецедентов;

- к составлению аналитических представлений закономерностей (АПЗ) изменения переменных типа «потребительские свойства объекта рассмотрения - параметры технологического процесса» с использованием метода линейных направлений - согласующих функций (ЛН-СФ) для формируемых классификационно-ориентирующих баз данных (КОБД) в области распознавания, прогнозирования и классификации свойств и характеристик исследуемых объектов.

Проблема оптимизации существующих технологий изготовления

тканей и проектирования новых тканей с заданными потребительскими свойствами выдвигает на первый план решение следующих задач:

1. Исследование существующих процессов формирования ткани и поведения потребительских свойств готовой продукции (размерные показатели, показатели структуры и волокнистого состава, показатели дефектности, эксплуатационные показатели) в зависимости от изменения технологических параметров (качество заправочных нитей, заправочные параметры станка, техническое состояние узлов станка, условия среды производства) и человеческого фактора.

2. Обобщение и систематизация имеющихся экспериментальных данных (изменение параметров строения различного вида тканей, имеющих разные структуры, под воздействием условий формирования ткани в процессе выработки на ткацком станке, в процессе отделки и эксплуатации) и создание на их основе первичных КОБД.

3. Разработка методологии создания классификационно-ориентирующих баз экспериментальных данных (КОБЭД) для вновь реализуемых технологических процессов на основе совершенствования составления АПЗ при расширении метода линейных направлений - согласующих функций (метод ЛН-СФ, Р)

4. Определение перспективных областей параметров реализованного технологического процесса ткачества, с целью получения значений потребительских свойств, отвечающих современным требованиям к объекту исследования – ткани.

5. Прогнозирование поведения потребительских свойств выходной продукции – ткани при проектировании новых технологий с использованием КОБЭД.

Методы решения.

В работе для решения указанных задач используется разработанный авторами расширенный метод линейных направлений и согласующих функций (ЛН-СФ, Р), являющийся развитием метода ЛН-СФ[1].

Отметим, что метод (ЛН-СФ, Р) характеризуется значительно большей размерностью описываемого признакового пространства за счет ортогональных аппроксимаций изменения основных переменных. Дальнейшее развитие (расширение) метода ЛН-СФ (метод ЛН-СФ, Р) позволит совершенствовать АПЗ для решения разного рода трудноформализуемых задач, в том числе и задач производство ткани с заданными потребительскими свойствами.

Для повышения точности АПЗ удобно пользоваться ансамблями ортогональных базисов (базисы Чебышева и Лагерра) [2], а также базисами полиномиального характера.

С целью расширения области прогнозирования потребительских свойств ткани, в частности для сглаживания описания внутри области

определения признаков, можно использовать ортогональные аппроксимации изменения основных переменных.

Литература

1. Саакян Р.Р. Системный анализ трудноформализуемых непрерывнозначных технологических задач // Диссертация на соискание ученой степени доктора технических наук. Благовещенск, 2002. 260 с.
2. Дедус Ф.Ф., Махортых С.А., Устинин М.Н., Дедус А.Ф. Обобщенный спектрально-аналитический метод обработки информационных массивов.// М. Машиностроение, 1999. 356 с.

Реализация расширенного метода линейных направлений-согласующих функций при прогнозировании поведения керамики под воздействием радиоактивного облучения

Р.Р. Саакян, И.А. Шпехт, Е.Н. Руденко

(Благовещенск)

Введение

Область применения керамических материалов расширяется с каждым годом. Благодаря их высокой радиационной стойкости, близкой к стойкости металлов и сплавов, керамические материалы играют важную роль в атомной и термоядерной энергетике

Как известно, под воздействием радиационного облучения происходит изменение свойств материалов вследствие нарушения их структуры. Взаимодействие различных видов излучений отличается разнообразием элементарных процессов и образованием большого количества радиационных дефектов, тип и количество которых зависит от энергии и вида излучений, а так же свойств облучаемого материала.

Значительные объемные изменения отдельных структурных фаз, составляющих керамический материал, могут вызывать существенные механические напряжения на их границах. Поскольку объемные изменения этих фаз при облучении различны и неодинаково меняются с ростом флюенса (предельной дозы облучения), то в облучаемом материале постоянно происходит перераспределение напряжений. Следствием этого является изменение многих свойств материала, таких, как предельная механическая прочность, электрическая прочность и др.

Условия использования керамических материалов в активной зоне атомного реактора и в некоторых узлах термоядерного реактора требуют дальнейшего повышения их радиационной стойкости при сохранении технологических свойств на уровне, позволяющем изготавливать достаточно крупные детали и изделия.

Постановка задачи

С целью разрешения вопросов проектирования новых керамических материалов с заданными свойствами и оптимизации существующих технологий их изготовления авторами были решены следующие задачи:

1. На основе известных моделей предложена математическая модель поведения керамики под воздействием радиационного облучения, где входными параметрами являются показатели содержания стеклофазы и кристаллофазы в материале и флюенс, а выходными параметрами являются электрические и механические прочностные характеристики материала.

2. Проведены обобщение и систематизация имеющихся экспериментальных данных (изменение структуры различных видов керамики, имеющих разное содержание кристаллофазы и стеклофазы, под воздействием облучения) и создана на их основе классификационно-ориентирующая база экспериментальных данных (КОБЭД).

Дальнейшее решение проблемы прогнозирования поведения керамических материалов при высоких дозах облучения, а также повышения их радиационной прочности, при сохранении технологических свойств, предполагает решение следующих задач:

1. Прогнозирование поведения керамики под воздействием радиоактивного облучения с использованием оперативной информации из обработанной КОБЭД.

2. Оценка изменения микроструктурных и прочностных характеристик керамики при проектировании новых керамических материалов с заданными свойствами на основе дальнейшей обработки КОБЭД.

Дальнейшая обработка экспериментальных данных весьма эффективна, если возможно по малым объемам экспериментов - прецедентов составить аналитические представления закономерностей (АПЗ) для выходных переменных.

Предложенный в работе метод составления АПЗ предназначен для получения закономерностей на основе экспериментальных данных, с ориентацией на значения функции в узловых точках сетки линейных направлений. Метод разработан для работы с непрерывными признаками, которые наиболее характерны для технологических объектов исследования.

Методы решения

С математической точки зрения прочностные характеристики электрокерамических материалов должны рассматриваться как случайные величины, подчиненные некоторому закону распределения.

С практической точки зрения часто необходимо знать, или, по крайней мере, иметь возможность прогнозировать величину вероятности разрушения материала при приложении определенной нагрузки, а также

при изменении вида напряженного состояния. Кроме того, ввиду наличия «масштабного эффекта», появляется необходимость прогнозировать прочность реальных конструкций на базе испытаний лабораторных образцов. Исходя из этого, при дальнейшей обработке полученных экспериментальных данных необходимо использовать такие методы обработки и анализа экспериментальных данных, которые затем можно использовать для экстраполяции за пределы измерений в область прогнозирования.

В предложенной работе для решения перечисленных задач дальнейшей обработки экспериментальных данных предлагается использовать разработанный авторами расширенный метод линейных направлений и согласующих функций (ЛН-СФ, Р), являющийся развитием метода ЛН-СФ[1].

Отметим, что метод (ЛН-СФ, Р) характеризуется значительно большей размерностью описываемого признакового пространства за счет ортогональных аппроксимаций изменения основных переменных. Еще одна особенность метода (ЛН-СФ, Р) состоит в том, что он применим к объектам различного содержания, в том числе и к объектам интеллектуального характера, включая ситуации, когда свойства объектов определяются органолептически, т.е. вручную.

Совершенствование АПЗ

Дальнейшее развитие (расширение) метода ЛН-СФ (метод ЛН-СФ, Р) вызвано необходимостью совершенствования аналитических представлений закономерностей (АПЗ) для решения разного рода трудноформализуемых задач.

В работе предлагается для совершенствования АПЗ опираться на описанные в литературе ансамбли функций, из которых наиболее подходящие варианты для аппроксимируемых функций выбираются варьированием (подбором) числовых значений параметров обозначенных ансамблей. Здесь в первую очередь рекомендуется воспользоваться ансамблями ортогональных базисов (базисами Чебышева и Лагерра) [2], при этом не исключаются и базисы полиномиального варианта.

На первом этапе в известной области описания признаков объектов решается задача определения аналитических представлений закономерностей по методу ЛН-СФ на основе малого объема экспериментальных данных.

На втором этапе на основе расчетных значений функции в узловых точках, которые несут в себе информацию о поведении функции также в промежуточных точках сетки, при опоре на использование ортогональных аппроксимаций изменения основных переменных, определяется описание функции по границам области изменения признаков объектов (метода ЛН-СФ, Р). Далее, на основе указанных описаний функции по границам,

получают уточняющее описание во всей области определения признаков. Для коррекции результатов полученного описания используются описания функции по промежуточным линейным направлениям, определенные на первом этапе (проверочная выборка линейных направлений).

Полученные результаты на основе использования ортогональных аппроксимаций изменения основных переменных можно использовать для сглаживания описания внутри области определения признаков (на стыках ячеек), а также при расширении области прогноза поведения функции.

Литература

1. Саакян Р.Р. Системный анализ трудноформализуемых непрерывнозначных технологических задач // Диссертация на соискание ученой степени доктора технических наук. Благовещенск, 2002. 260 с.
2. Дедус Ф.Ф., Махортых С.А., Устинин М.Н., Дедус А.Ф. Обобщенный спектрально-аналитический метод обработки информационных массивов.// М. Машиностроение, 1999. 356 с.

Реализация одного алгоритма понижения значности исходной информации в системах с параллельными вычислениями

А.А. Сахаров
(Москва)

Применение логических (дискретных) процедур распознавания в случае вещественнозначной информации или целочисленной информации высокой значности оказывается весьма затруднительным. Один из способов решения этой задачи связан с корректным перекодированием исходной выборки. Число корректных перекодировок растет экспоненциально с ростом размеров задачи. Эту проблему можно решить выбором из всего множества перекодировок одной или нескольких перекодировок, удовлетворяющих некоторому критерию качества. Таким критерием может являться число типичных значений признаков [1, 2] в перекодированной таблице обучения.

Ранее был разработан алгоритм поиска «наилучшей» (в смысле числа типичных значений) перекодировки исходной информации, основанный на построении корректной перекодировки с максимальным числом типичных значений [1, 3]. Однако в некоторых случаях применение данного алгоритма представляет собой определенную сложность, связанную с наличием большого перебора и, как следствие, требуются значительные вычислительные ресурсы. Использование параллельных вычислительных технологий позволяет достаточно эффективно сократить время счета. В докладе рассматривается эффективная реализация

указанного алгоритма в системе с параллельными вычислениями (комплекс МВС-1000/М). Для программной реализации используется интерфейс MPI, C++.

Обработка данных алгоритмом может быть разбита на три этапа. На первом этапе происходит построение множества пороговых значений для каждого признака, с последующим построением булевой матрицы специального вида. На втором этапе ведется перекодирование каждого столбца исходной матрицы в отдельности с целью выявления перекодировки с максимальной информативностью. Следующий этап – «сборка» перекодированной матрицы из полученных перекодировок столбцов и проверка ее на корректность.

Самым трудоемким с точки зрения вычислений является второй этап, который представляет из себя перебор множества пороговых значений для каждого столбца. Эту процедуру можно эффективно реализовать в системе с параллельными вычислениями.


Далее приведена схема реализации алгоритма.

- Выделяется управляющий процессор с (УП), который выполняет предварительную обработку исходной матрицы, передает рабочим процессам столбцы матрицы для обработки.
- УП осуществляет «сборку» перекодированной таблицы из столбцов, полученных от рабочих процессов, проверяет полученную таблицу на корректность, в случае некорректности последней дает рабочим процессам команду на поиск следующих вариантов перекодировок столбцов, последовательно замещая новыми вариантами ранее полученные и проводя проверку на корректность.
- Получив корректную перекодировку алгоритм заканчивает работу. Если же корректная перекодировка не была найдена, искомая значность повышается на единицу и алгоритм начинает работу с начала.

Ниже приведены результаты счета описанного выше алгоритма на случайных таблицах с числом строк равным 100 и числом столбцов - 20. Таблица была разбита на два класса по 50 объектов в каждом.

Число процессоров	2	3	5	7	9
Время счета	144,5	71,6	37,1	31,2	18,8

Число процессоров	11	13	15	17	19	21
Время счета	15,4	12,7	11,3	9,4	9,2	8,7



Работа выполнена при частичной финансовой поддержке РФФИ (коды проектов 05-01-00495 и 04-01-00795).

Литература

1. Дюкова Е.В., Песков Н.В. Поиск информативных фрагментов описаний объектов в дискретных процедурах распознавания // Ж. вычисл. матем. и матем. физ. 2002. Том 42, № 5. С. 741-753.
2. Песков Н.В., Сахаров А.А. Об одном подходе к понижению значности исходной информации в задачах распознавания // Докл. Всеросс. Конф. «Матем. методы распознавания образов – 11». М.: Регион-Холдинг, 2003, С. 160-162.
3. Дюкова Е.В., Журавлев Ю.И., Песков Н.В., Сахаров А.А. Обработка вещественнозначной информации логическими процедурами распознавания // Искусственный интеллект. Журнал НАН Украины. 2004. №.2. С. 80-85.

Представление геометрического объекта списком метрических характеристик

А.А. Свенч, Р.Т. Файзуллин
(Омск)

Постановка задачи

В работе рассматриваются представление геометрического объекта неупорядоченным списком его метрических характеристик. Показано, что данное представление, при наличии минимальной ключевой информации, позволяет однозначно восстанавливать объект. Предложены алгоритмы защищенной передачи метрической информации о геометрическом объекте, предварительно заданном набором вершин и граней

(полигональная модель). Проведены предварительные исследования стойкости криптопротокола.

Алгоритм представления геометрического объекта в виде списка метрических характеристик

На вход алгоритма поступает набор вершин A_i объекта, заданного координатами x_{ij} в n -мерном пространстве:

$$\begin{cases} A_1 = (x_{11}, x_{12}, \dots, x_{1n}) \\ A_2 = (x_{21}, x_{22}, \dots, x_{2n}) \\ \dots \\ A_k = (x_{k1}, x_{k2}, \dots, x_{kn}) \end{cases} \quad (1)$$

Алгоритм работает итеративно. Каждая последующая точка A_i обрабатывается на основе предыдущих точек: вычисляются величины $R_{i1}, R_{i2}, \dots, R_{in}$, являющиеся квадратами расстояний от A_i до каждой из предыдущих n точек:

$$\begin{cases} R_{i1} = (\rho(A_{i-n}, A_i))^2 = \sum_{j=1}^n (x_{ij} - x_{(i-n)j})^2 \\ R_{i2} = (\rho(A_{i-n+1}, A_i))^2 = \sum_{j=1}^n (x_{ij} - x_{(i-n+1)j})^2 \\ \dots \\ R_{in} = (\rho(A_{i-1}, A_i))^2 = \sum_{j=1}^n (x_{ij} - x_{(i-1)j})^2 \end{cases} \quad (2)$$

При восстановлении каждой точки объекта необходим еще один параметр, определяющий выбор одной из двух точек, расположенных симметрично относительно гиперплоскости, образуемой точками $A_{i-1}, A_{i-2}, \dots, A_{i-n+1}, A_{i-n}$ и удовлетворяющих системе уравнений (2). В качестве такого параметра целесообразно использовать знак векторного произведения всех векторов, образуемых точкой A_i и каждой из n предыдущих:

$$k'_i = \text{sign}(\overrightarrow{A_{i-n}A_i} \otimes \overrightarrow{A_{i-n+1}A_i} \otimes \dots \otimes \overrightarrow{A_{i-1}A_i}) \quad (3)$$

Таким образом, при преобразовании объекта точке A_i в n -мерном пространстве соответствуют значения R_{ij} и параметр k_i .

Значения координат стартовых точек $A_0, A_1, \dots, A_{-n+2}, A_{-n+1}$ являются ключевыми. Их можно генерировать с помощью криптостойкого

генератора псевдослучайных чисел.

Алгоритм восстановления геометрического объекта

Восстановление объекта по выходным параметрам описанного выше алгоритма также происходит итеративно: на i -й итерации по значениям R_{ij} находим точки A_i', A_i'' , удовлетворяющие (2) и расположенные симметрично относительно гиперплоскости, образуемой точками $A_{i-1}, A_{i-2}, \dots, A_{i-n+1}, A_{i-n}$. Для выбора искомой A_i вычисляем знак векторного произведения всех векторов, образуемых точкой A_i и каждой из n предыдущих точек

$$k_i' = \text{sign}(\overrightarrow{A_{i-n}A_i'} \otimes \overrightarrow{A_{i-n+1}A_i'} \otimes \dots \otimes \overrightarrow{A_{i-1}A_i'}) \quad (4)$$

$$A_i = \begin{cases} A_i', & \text{если } k_i' = k_i \\ A_i'', & \text{иначе} \end{cases} \quad (5)$$

Стойкость метрического представления объекта

При использовании описанного выше алгоритма преобразования топологических характеристик геометрического объекта в метрические конфиденциальность информации базируется на невозможности восстановления объекта без ключевой информации. В данном случае ключевой информацией являются n стартовых точек, по которым алгоритм восстановления итеративно вычисляет вершины объекта. У злоумышленника, пытающегося восстановить объект, имеются только значения R_{ij} и k_i . В конкретных случаях злоумышленник может получить некоторую информацию о топологии объекта:

Если объект задан вершинами с целочисленными координатами, то злоумышленник, имея такую информацию, может представить R_{ij} в виде суммы квадратов n целых чисел (смещений по осям координат) и таким образом найти топологическое представление объекта в виде множества ребер. Для решения этой проблемы можно при вычислении R_{ij} фигурирующие в (2) расстояния учитывать со случайной погрешностью $\varepsilon_{ij} \in (-0,5 \dots 0,5)$

$$\left\{ \begin{array}{l} R_{i1} = (\tilde{\rho}(A_{i-n}, A_i))^2 = \sum_{j=1}^n (x_{ij} - x_{(i-n)j} + \varepsilon_{ij})^2 \\ R_{i2} = (\tilde{\rho}(A_{i-n+1}, A_i))^2 = \sum_{j=1}^n (x_{ij} - x_{(i-n+1)j} + \varepsilon_{ij})^2 \\ \dots \\ R_{in} = (\tilde{\rho}(A_{i-1}, A_i))^2 = \sum_{j=1}^n (x_{ij} - x_{(i-1)j} + \varepsilon_{ij})^2 \end{array} \right. \quad (6)$$

В этом случае величины R_{ij} , идущие на вход каналов, будут приближенными значениями суммы квадратов, и для восстановления отдельных расстояний злоумышленнику придется перебирать все варианты на некоторой n -мерной сфере.

Другое решение проблемы конфиденциальности передаваемого объекта состоит в усложнении перехвата информации злоумышленником. Этого можно добиться разделением передаваемой информации на несколько потоков данных, которые по отдельности не дадут злоумышленнику возможности для восстановления каких-либо топологических характеристик объекта.

Основная идея разделения информации на несколько потоков описана в работе [1]. В данном случае в качестве потоков могут использоваться потоки, содержащие R_{ij} , так что в j -й поток помещаются все R_{ij} . При перехвате каких-либо t потоков, $t < n$, злоумышленнику придется восстанавливать точки в n -мерном пространстве по t -мерным объектам, что является неразрешимой задачей при отсутствии дополнительной информации об объекте. Т.е., если следовать физической аналогии, предлагается разделять «жесткий» объект (сообщение) на несколько объектов, каждый из которых гарантированно будет иметь много степеней свободы.

Литература

1. Ефимов В.И., Файзуллин Р.Т. Система мультиплексирования разделенного TCP/IP трафика // Математические структуры и моделирование, 2002. Вып.10. С. 170-171.

Метод биометрической идентификации личности по форме ладони

А.Б. Семенов, Д.А. Чертоусов
(Тверь)

Среди известных на сегодняшний день методов биометрической идентификации метод, основанный на сравнении формы ладоней, занимает особое место. Несмотря на то, что в настоящее время растет популярность систем, использующих для решения задачи распознавания дактилоскопические данные, изображение радужной оболочки глаза, системы идентификации на основе геометрии (формы) ладони остаются востребованными на рынке. Это обусловлено, во-первых, относительно простым способом получения изображения ладони, не требующих дорогих специализированных сканирующих устройств, и, во-вторых, приемлемым уровнем качества распознавания для систем контроля доступа со средним уровнем требований к безопасности.

При использовании биометрических технологий существуют общие подходы к решению задачи идентификации. Биометрическая система распознавания устанавливает соответствие конкретных физиологических или поведенческих характеристик пользователя некоторому заданному шаблону. Применение биометрических технологий предполагает выполнение следующих основных этапов:

- получение биометрического образца от человека;
- извлечение из него биометрических данных;
- сравнение этих данных с одним или несколькими данными такого же типа, хранящимися в базе данных;
- определение степени совпадения предъявленных данных с данными из базы;
- выработку решения об идентификации человека по предъявленным данным.

Наиболее важными параметрами любой системы идентификации являются следующие:

- FAR (False Acceptance Rate) – «пропуск цели» или вероятность того, что «чужой» будет принят за «своего» (ошибка первого рода);
- FRR (False Rejection Rate) – «ложная тревога» или вероятность того, что «свой» будет принят за «чужого» (ошибка второго рода);
- скорость сравнения хранящейся в базе информации с предъявленным для контроля биометрическим описанием.

Традиционные методы биометрической идентификации по геометрии ладони используют в качестве шаблона вектор измерений геометрических параметров руки в отдельных точках. Вследствие этого эффективность таких методов является недостаточной, что обуславливает необходимость проведения дальнейших исследований по развитию данного класса систем.

Другим недостатком большинства существующих систем является необходимость жесткого позиционирования ладони на сканирующем устройстве, что создает неудобства при пользовании системой. Фиксированное позиционирование достигается размещением на поверхности сканера ограничителей положения ладони (рис. 1).




Рис. 1. Традиционные системы идентификации по форме ладони.

Идея принципиально нового метода биометрической идентификации личности по форме ладони предложена в работе [1]. В основе метода лежит подход, основанный на аппроксимации изображения ладони непрерывными геометрическими примитивами, так называемыми жирными линиями (объединение однопараметрического семейства кругов переменного радиуса с центрами на гладких кривых) и сравнении их между собой. По сравнению с традиционными методами предложенный подход обеспечивает большую информативность признакового описания. Пример аппроксимации растрового образа ладони жирными линиями представлен на рис.2.




Рис. 2. Аппроксимация растрового образа ладони жирными линиями.

Способ извлечения параметрического описания формы ладони включает в себя следующие этапы:

- выделение ладони в виде аппроксимирующего многоугольника на входном изображении;
- построение срединных осей (скелета) полигональной фигуры ладони;
- аппроксимация ветвей скелета жирными B-сплайновыми кривыми и идентификация пальцев ладони;

- построение и сравнение характеристических функций пальцев руки;
- выбор прецедента по критерию максимума меры сходства с предъявленным образом и принятие решения о распознавании.

Вероятности первого (P_e^1) и второго (P_e^2) рода находятся в обратной зависимости, а соотношение между ними определяет порог принятия решения α . Выбор порога должен быть произведен таким образом, чтобы вероятность P_e^1 была минимальной, при этом вероятность P_e^2 не превосходила бы заданного ограничения. С целью определения порога α , при котором обеспечивается решение указанной задачи, был проведен эксперимент, который позволил построить зависимости вероятностей ошибок первого и второго рода от величины порога. Эксперимент производился на выборке изображений ладоней, включающей 408 изображений ладоней, по 8 различных изображений от 51 человека. Данная выборка была любезно предоставлена Болонским университетом (Цезена, Италия) в рамках международного сотрудничества.

Суть эксперимента заключалась в следующем. Из 408 изображений ладоней, имевшихся в наличии, 208 (от 26 человек) из них были помещены в базу данных прецедентов. Затем все 408 образов распознавались на созданной прецедентной базе. Эксперимент проводился многократно для различных значений порога. Величина порога измеряется в условных единицах и измеряется в пределах от 0 до 100.

На рис. 3 показаны зависимости вероятности P_e^1 (FAR) и P_e^2 (FRR) от величины порога.




Рис. 3. Порог принятия решения.

На графиках видно, что при заданном ограничении на вероятность $P_e^2 \leq 2\%$ минимальное значение вероятности P_e^1 , равное 0.74%, достигается при пороге, составляющим 97.95.

Следует также отметить, что разработанный метод обеспечивает порядка 372 сравнений в секунду образов из прецедентной базы с предъявляемыми данными на персональном компьютере с процессором 1.8 ГГц.

Работа выполнена при поддержке РФФИ (гранты 05-01-00542, 04-01-08058).

Литература

1. L. Mestetskiy, A. Semenov. Palm shape comparison based on fat curves. Pattern Recognition and Image Analysis, vol.15, #3, 2005.

Свойства модели объекта в системе распознавания с активным сенсором

С.Ю. Сергунин, М.И. Кумсков
(Москва)

Введение

Основой системы распознавания объектов с активным сенсором (РОАС) является понятие модели объекта [1]. Модель строится в процессе обучения системы и определяет выбор существенных признаков объекта на этапе распознавания [2]. В работе представлены свойства модели, определяющие ее функциональность.

Постановка задачи распознавания в РОАС системе

Основная задача модели объекта в РОАС системе - управление процессом распознавания, включая последовательное задание положения окна сканирования сцены – «центра зрения» активного сенсора (АС). В результате объектная модель (ОМ) определяет существенные для своей формы параметры, характеризующие распознаваемый предмет в терминах расположения особых точек внутри контура предмета на проекции. Сформулируем постановку задачи распознавания в РОАС системе, которая определяет набор функций моделей модели объекта.

Задача распознавания в РОАС системе:

Дано: (1) Набор (база данных) объектных моделей *OMDB*, построенных в процессе обучения. Каждая модель соответствует распознаваемому предмету на сцене; (2) Входная сцена S_c , содержащая набор предметов в различной ориентации;

Путем последовательного определения положений центра зрения АС требуется: получить следующий результат распознавания:

- Получена «объектная сегментация» сцены S_c на участки, содержащие проекции объектов так, что каждым участком «владеет» своя модель *ОМ*.
- Для каждого участка определена ориентация наблюдателя Obs относительно объекта O в системе координат объекта.
- Сформирована «карта местности» сцены, содержащая координаты опознанных объектов, их ориентацию в трехмерном пространстве в системе координат наблюдателя.

При обучении РОАС системы строятся модели объектов, которые затем управляют процессом распознавания [2].

Свойства модели

Введем некоторые определения:

Описание окрестности маркированной особой точки (МОТ) sp [3,4] как набора ближайших к ней МОТ в данной специфической ориентации, назовем конфигурацией маркированных особых точек (КМОТ), где sp – центральная точка КМОТ.

Функция близости КМОТ – это функция сравнения двух конфигураций МОТ, сформированных в одном алфавите [2].

Реперная особая точка (РОТ) rsp – это маркированная особая точка, выделенная на проекции объекта при ее анализе на этапе обучения. РОТ используется на этапе распознавания для подтверждения похожести конфигурации МОТ проекции и конфигурации МОТ сцены. Для каждой проекции объекта определен набор РОТ, и каждой РОТ соответствует некоторый алфавит.

Перейдем к свойствам модели. Модель объекта содержит представление объекта и выполняет следующие функции.

Описание окна сенсора в заданном алфавите. Описание представляет собой набор конфигураций особых точек (КМОТ), найденных и классифицированных в заданном алфавите.

Вычисление функции близости для двух наборов КМОТ. Для двух наборов КМОТ близость вычисляется как сумма близостей отдельных КМОТ с совпадающими центральными точками. Т.е. близость КМОТ с различными центральными точками мы не рассматриваем и считаем ее равной 0.

Вычисление рейтинга проекции Рейтинг вычисляется как сумма значений функции близости наборов КМОТ внешней проекции сцены и внутренней проекции объекта.

Установка параметров активной проекции объекта. При активизации внутренней проекции модели объекта происходит перенос параметров внутренней проекции на область внешней проекции сцены. То есть выдвигается гипотеза о соответствии этих проекций, и в рамках этой гипотезы на области проекции сцены задаются следующие предположения:

Ориентация и удаление объекта относительно наблюдателя. То есть проекция может вычислить координаты нахождения наблюдателя в системе координат объекта. Так же по относительным расстояниям между соответствующими МОТ делается предположение об удаленности объекта от наблюдателя.

Набор реперных особых точек (РОТ). На основании уже найденных соответствиях МОТ делается предположение о нахождении реперных особых точек проекции. Набор РОТ представляет собой двумерную проекцию облака 3Д-ПТО на плоскость, перпендикулярную линии

визирования наблюдателя. Для каждой РОТ набора определены следующие параметры:

- Координаты РОТ в системе координат объекта.
- Алфавит, в котором она была найдена
- Маркер класса в этом алфавите.

Силуэт объекта. Силуэт задается таким образом, что для любой точки проекции можно сказать: попадает она в область, ограниченную силуэтом или нет. Например, силуэт может быть задан системой линейных (квадратных) неравенств.

Подтверждение активной проекции модели. Эта функция объединяет в себе совокупность следующих функций:

Задание координат ЦСС. Проекция передает координаты одной из своих РОТ для установки в нее центра зрения.

Отсечение по силуэту. Т.к. на проекции сцены был задан силуэт, из описания удаляются все точки, не попадающие в силуэт.

Закрепление проекции модели за область сцены. Это означает, что объект подтверждает параметры активной модели:

1. Расположение наблюдателя
2. Набор РОТ
3. Силуэт объекта.

На карте сцены отмечаются координаты объекта, его ориентация относительно наблюдателя и выделяется его силуэт.

Заключение

Определены свойства модели объекта, позволяющие использовать их в системе распознавания объектов с активным сенсором (РОАС). Активный сенсор является неотъемлемой компонентой процесса распознавания, и его использование позволяет резко сократить объемы вычислений, локализуя их в рамках окна обработки, положение которого задается «центром зрения» АС.

Литература

1. Сергунин С.Ю., Квашнин К.М., Кумсков М.И. Схема динамического построения многоуровневого описания изображений // Доклады конференции «Математические методы распознавания образов (ММРО-12-2005)», стр. 436-439
2. Сергунин С.Ю., Кумсков М.И., Вычислительная Модель Расознавания Объектов Сцен с Активным Сенсором // Pattern Recognition and Image Analysis, Vol. 16, 2006, (в печати).
3. Kvashnin K., Sergunin S., Kumskov M. Construction of the Marked Graph of an Image and Its Invariants in the Classification Problem. // Pattern Recognition and Image Analysis, Vol. 13, No. 1, 2003, pp 135-137.
4. Sergunin S., Kvashnin K., Kumskov M. Using Image Representation Families for Recognition Based on Symbol Marking of Singular Points. //

Диалоговое обучение системы распознавания сцен с активным сенсором

С.Ю. Сергунин, М.И. Кумсков
(Москва)

Введение

Важной стадией построения системы распознавания сцен является обучение системы. В работе предложено проводить обучение системы распознавания с участием человека-оператора в диалоговом режиме. Описаны две роли процесса: настройщик и исследователь. Существенной компонентой системы является активный сенсор – сканирование сцены проводится его окном по заданным положениям «центра зрения». Особенность обучения состоит в том, что человеку-оператору, нужно настроить последовательность расположений центра зрения активного сенсора (АС) при распознавании предметов сцены.

Постановка задачи

Задача обучения системы распознавания объектов с активным сенсором (РОАС) в диалоге с оператором может быть сформулирована так:

Дано: Оператору предъявляются набор учебных проекций данного предмета.

Требуется: Оператору нужно в интерактивном режиме сформировать объектную модель (*ОМ*) предмета, так чтобы:

- *ОМ* удовлетворяла заданным свойствам модели объекта [1] и могла быть использована на этапе распознавания сцены.
- При тестировании модель *ОМ* однозначно идентифицировала предмет на фоне других объектов.

Роли оператора

Система в процессе обучения может работать с операторами двух типов: **Настройщик** и **Исследователь**.

Задача **Настройщика** – для данной предметной области подготовить наборы алфавитов и рекомендации по их использованию при построении *ОМ*, а также наборы функций построения КМОТ и функций сравнения КМОТ [1].

Задача **Исследователя** – экспертное построение и отладка объектной модели предмета. Построение *ОМ* включает создание 3D-ПТО – трехмерного облака пространственных точек описания объекта на основе обучающих проекций предмета.

Введем понятие проекта предметной области. Проектом назовем совокупность данных и настроек, позволяющих создавать модели

объектов и проводить распознавание в рамках данной предметной области. Проект включает:

- Алфавиты особых точек
- Набор учебных проекций предметов из данной предметной области.
- Функции построения КМОТ
- Функции сравнения КМОТ

Функции Настройщика

Построение алфавита особых точек.

Алфавит особых точек строится на основе вспомогательных функций:

- Фильтры для обработки окна (изображения) АС. (*filterImage*)
- Функции идентификация ОТ в окне АС. (*findSP*)
- Функции построения описания окрестности ОТ окна АС в виде вектора признаков, на основе которого проводится классификация ОТ. (*describeSP*)

1) Методы классификации и разметки ОТ окна АС в соответствии с векторами признаков. (*markSP*)

Вспомогательные функции одного типа объединяются в списки. При создании обновлении алфавита **Настройщик** выбирает вспомогательную функцию из соответствующего списка и добавляет ее в алфавит. Для работы со списками задаются стандартные функции: *create*, *read*, *update*, *delete* (*CRUD*).

Формирование списков функций построения и сравнения конфигураций маркированных особых точек (КМОТ).

В системе предусмотрено несколько способов построения и сравнения КМОТ, объединенных в списки. Задача **Настройщика** – подготовить реализации этих методов и загрузить их в систему и проверить их работу. Для работы со списком используются функции *CRUD*.

Функции Исследователя

1. Создание модели объекта.

Задан набор обучающих проекций объекта с определенными для каждой проекции положениями наблюдателя. Требуется построить модель объекта, удовлетворяющую свойствам модели и выполняющую функции модели. Порядок выполнения:

Исследователь определяет предметную область объекта и загружает проект в **Систему**. Загружает в новую модель все имеющиеся проекции с заданными положениями наблюдателя. На каждой проекции отмечает силуэт объекта.

Исследователь задает алфавит [2] по умолчанию и запускает поиск и классификацию особых точек (ОТ) в рамках заданного на всех проекциях объекта. Задает порядок обхода ОТ окном АС. Задает функцию построения конфигураций особых точек в окне АС. **Система** строит

КМОТ в «алфавите по умолчанию» на всех проекциях и сохраняет их.

Исследователь выбирает из всего набора проекций – «опорные» проекции и создает новое трехмерное описание объекта (3D-ПТО).

Исследователь (на экране монитора «мышкой») отмечает на опорных проекциях реперные особые точки в алфавите по умолчанию. **Система** строит для РОТ их конфигурации с другими МОТ в алфавите по умолчанию. Переопределяется порядок обхода МОТ окном АС.

Исследователь добавляет отмеченные РОТ вместе с их конфигурациями в 3D-ПТО.

Исследователь проводит дополнительный анализ опорных проекций для выявления потенциальных РОТ, которые не были включены в 3D-ПТО, а также определяет предполагаемые алфавиты, в которых эти РОТ могут быть обнаружены. После этого он запускает обработку опорных проекций в предполагаемых алфавитах. **Система** проводит обработку и отображает отклассифицированные особые точки.

Исследователь совмещает вновь обработанные проекции с уже сформированным облаком точек, отмечает те реперные точки, которые в него не вошли и добавляет их в 3D-ПТО. При этом для каждой РОТ сохраняется следующая информация:

1. Относительные координаты РОТ
2. Алфавит, в котором она была найдена
3. Маркер класса в этом алфавите.
4. КМОТ, отдельно для каждого способа построения конфигурации.

Исследователь задает функцию сравнения КМОТ и сохраняет ее в данной модели.

2. Распознавание объектов на тестовых изображениях.

Функция предназначена для проверки корректности построенной модели объекта. Задается набор тестовых изображений, содержащий проекции нескольких объектов, в том числе и соответствующего тестируемой модели. **Исследователь** выбирает проект предметной области, включает запись протокола в **Системе** и запускает автоматический процесс распознавания. После окончания распознавания **Исследователь** оценивает результаты.

3. Уточнение модели объекта.

Если результаты распознавания неудовлетворительные, **Исследователь** анализирует протокол, выявляет недостатки модели и производит ее уточнение. Конкретные действия **Исследователя** определяются в зависимости от типов ошибки распознавания.

4. Компиляция проекта предметной области.

Компиляция предметной области – это процедура окончательной «сборки» проекта предметной области. При этом **Система** автоматически сравнивает «похожесть» проекций разных объектов по РОТ. В случае,

если проекции двух различных объектов близки настолько, что неразличимы для **Системы**, она сообщает об этом, и **Исследователь** возвращается к уточнению моделей.

Заключение

Разработан диалоговый процесс обучения системы и сформулированы задачи и основные сценарии работы оператора системы распознавания с активным сенсором. Проводится реализация описанных сценариев в виде программной системы.

Литература

1. Сергунин С.Ю., Кумсков М.И. Свойства модели объекта в системе распознавания с активным сенсором. // Настоящий сборник.
2. Sergunin S., Kvashnin K., Kumskov M. Using Image Representation Families for Recognition Based on Symbol Marking of Singular Points. // Pattern Recognition and Image Analysis, Vol. 13, No. 3, 2003, pp 531-538

Примеры построения алфавитов описания окна активного сенсора в РОАС системе

С. Сергунин, А. Миловидов, В. Лозинский, Д. Кравченко

(Москва)

Введение

Построение алфавитов описания окна активного сенсора – это первичная задача обучения системы распознавания с активным сенсором - РОАС [1,2]. Сенсор формирует окна оцифровки, на которых система проводит символьную разметку особых точек (ОТ) в заданном алфавите. Таким образом, именно алфавит задает правила обработки проекций сцены для построения их описания в виде, удобном для последующего распознавания. В работе представлены различные варианты построения алфавитов описания.

Задача построения алфавитов описания в РОАС системе

Определим понятие алфавита описания [2]:

Алфавит описания ASP – это тройка $(findSP(p), markSP(p), M)$, где:

- $findSP(p)$ - функция идентификации ОТ на изображении p ;
- $markSP(p)$ - функции классификации ОТ на изображении p , обработанном функцией $findSP(p)$;
- $M = \{M_1, \dots, M_n\}$ - набор символьных маркеров, используемых при разметке ОТ сцены.

Таким образом, задача построения алфавита описания сводится к созданию функций идентификации и классификации особых точек:

Дано: (1) Набор проекций сцен из определенной предметной области. Требуется построить (1) функцию идентификации и (2) классификации ОТ

на сценах из заданной предметной области.

Рассмотрим последовательно эти подзадачи.

Построение функции идентификации особых точек

Поиск особых точек на изображении включает следующие этапы:

1. Фильтрация изображения
2. Выделение контуров на изображении.
3. Очистка контуров.
4. Нахождение особых точек контуров

Рассмотрим примеры построения функций классификации. К исходному изображению (рис. 1), считаем, что оно уже предварительно обработанное (очищенное от шума, сглаженное, достаточно контрастное и резкое), применяем функцию выделения контуров. В данном случае используем алгоритм Собеля (рис. 2). После этого к полученным контурам применяем морфологические преобразования бинарных изображений, позволяющие убрать разрывы и сгладить контуры. Например, применим сначала функцию расширения контуров (Рис. 3), а потом их сжатия (Рис. 4).




Рис. 1 Исходное изображение.
(Собель).

Рис. 2 Выделенные контуры

Рис. 3 Расширение контуров.

Рис. 4 Сжатие контуров.

В нашей работе для нахождения ОТ на контурах применяются различные

алгоритмы. В качестве примера возьмем следующие:

1. Вычисление кривизны контура в квадрате изображения (7x7). Если кривизна больше заданного порога, считаем, что в центре квадрата находится ОТ, которую отмечаем (Рис. 5).




Рис. 5 Кривизна контуров.




Рис. 6 Пересечение контуров.

2. Нахождение особых точек как пересечений контуров (Рис. 6).

Построение функции классификации особых точек

Классификация особых точек проводится на исходном изображении (Рис. 1). Выделяем для каждой точки окрестность некоторого радиуса и на основании ее описания формируем вектор признаков. После этого к векторам применяем алгоритмы кластер-анализа, и найденным кластерам ставим в соответствие символьные маркеры. Эти маркеры и формируют набор $M = \{M_1, \dots, M_n\}$.

Среди возможных функций описания окрестностей ОТ в виде вектора признаков мы использовали следующие: взятие коэффициентов дискретного косинусного преобразования, коэффициентов преобразования Фурье, взятие моментов: среднее, дисперсия, третий момент. Также применяли вейвлет-преобразования. Среди алгоритмов кластер-анализа применялся иерархический кластер анализ и алгоритм k-средних. (Рис. 7)

Заключение

В работе представлены примеры реализаций алфавитов описания для системы распознавания с активным сенсором.



Рис. 7. Размеченные ОТ. После взятия моментов, алгоритм k-средних ($k=4$).

Литература

1. Сергунин С.Ю., Кумсков М.И Диалоговое обучение системы распознавания сцен с активным сенсором. // Настоящий сборник.
2. Сергунин С.Ю, Кумсков М.И., Вычислительная Модель Расознавания Объектов Сцен с Активным Сенсором // Pattern Recognition and Image Analysis, Vol. 16, 2006, (в печати).

Меры оценки качества классификации многоспектральных изображений

В.С. Сидорова
(Новосибирск)

Введение

Рассматривается задача управления детальностью неконтролируемой классификации, основанной на многомерной гистограмме. Предлагаются некоторые меры и критерии для поиска лучшей классификации. Гистограмма рассматривается как аппроксимация плотности вероятности многоспектральных векторов изображения. Пики или, иначе, локальные максимумы гистограммы являются модальными векторами искомым кластеров. Алгоритмы, разделяющие гистограмму по унимодальным кластерам, давно известны и широко используются [1,2]. Чтобы классифицировать векторы изображения с разной степенью детальности, полученные кластеры можно объединять различными методами, но при этом унимодальность кластеров может быть нарушена. Здесь предлагается другой путь: масштабировать пространство исходных многоспектральных векторов, ввести меру качества классификации как функцию от

коэффициента масштабирования и найти лучшую классификацию для различных уровней детализации.

Меры качества классификации

Спектральные интенсивности каждого канала квантуются на 256 уровней. Введем коэффициент масштабирования $kf * S(k)$, где $\kappa=1,2,\dots,L$, L – число спектральных каналов, kf – вещественный регулятор масштабирования. Пусть $\mathbf{f}=[f(1),f(2),\dots,f(L)]$ – многоспектральный вектор изображения, а $\mathbf{d}=[d(1),d(2),\dots,d(L)]$ – вектор, в который преобразуется \mathbf{f} в результате масштабирования:

$$d_k = INT\left(\frac{f(k)}{kf * S(k)}\right), k = 1, \dots, L.$$

Если $kf > 1$, то количество различных векторов \mathbf{d} меньше, чем \mathbf{f} . Классифицируем новые вектора. Опишем известную меру 1 качества классификации.

Мера 1. Сначала определим качество отдельного кластера.

$$S^m(kf) = \frac{|D^m(kf) - D^{j^*}(kf)|}{d^m(kf)}, \text{ где } D^m(kf) = \frac{N_s^m(kf)}{N_c^m(kf)}, \quad (1)$$

$N_s^m(kf)$ – общее число векторов кластера, а $N_c^m(kf)$ – число различных векторов, так что $D^m(kf)$ – средняя плотность вероятности m -го кластера.

$$d^m(kf) = \min_{j(j \neq m)} \|C^m(kf) - C_j^m(kf)\|, j = 1, 2, \dots, K(kf),$$

j^* – это значение j , полученное при минимизации верхнего выражения, т.е. это номер ближайшего кластера. Здесь $K(kf)$ – общее число кластеров, $C^j(kf)$ – координаты пиков кластеров.

Мера качества распределения векторов для данного kf определяется так:

$$S(kf) = \frac{1}{K(kf)} \sum_{m=1}^{K(kf)} S^m(kf). \quad (2)$$

Хорошим распределением будем считать такое, с учетом (1), когда все кластеры имеют высокую плотность и далеко отстоят друг от друга. Такому распределению будут соответствовать маленькие значения $S(kf)$.

Мера 2. Для унимодальных кластеров мы предлагаем еще одну меру:

$$S^m(kf) = \frac{1}{M^m(kf)} \sum_{i=1}^{M^m(kf)} \frac{h_i^m(kf)}{H^m(kf)},$$

где $h_i^m(kf)$ значение гистограммы в i -той точке границы кластера, $H^m(kf)$ значение гистограммы в пике кластера, $M^m(kf)$ - число точек границы кластера, либо

$$\text{Мера 3: } S^m(kf) = \max_i \frac{h_i^m(kf)}{H^m(kf)}, i = 1, 2, \dots, M^m(kf) .$$

Полная мера качества распределения кластеров для данного kf определяется так же, как и в (2). Здесь также лучшим распределениям соответствуют минимумы $S(kf)$ по kf . Меры 2 и 3 дешевле меры 1 в вычислительном отношении. Точки минимумов для всех мер, видимо, должны быть близки. Так же как для меры 1, большие плотности всех кластеров уменьшают значение мер 2 и 3, а маленькие плотности векторов на их границах характерны для удаленных и хорошо разделенных соседних кластеров.

Эксперименты

Классифицировалось трехспектральное спутниковое изображение тающих снегов поверхности Земли. Исследовалось поведение всех трех мер. Коэффициент kf изменялся от 4 до 54,4, т.е. до такого значения, когда получился один кластер. Минимумы достигались в одних и тех же точках kf для мер 1 и 2. Для меры 3 точки минимумов отличались, но незначительно. Для значений $kf < 4$ значения мер чрезвычайно малы, но очень много кластеров. В интервале от 4 до 16 найдено три минимума, причем два глубоких и примерно совпадающих по значениям мер. Они соответствовали 54 и 10 кластерам. В оставшемся интервале найдено пять незначительных минимумов.

Выводы

Меры 1 и 2 могут использоваться для оценки качества классификации. Мера 3 представляет более жесткий критерий и может быть использована для оценки качества отдельных кластеров.

Работа выполнена частично при финансовой поддержке Российского фонда фундаментальных исследований (проект № 05-07-90057-В).




Рис. 1. Вверху слева трехспектральное изображение тающих снегов. На остальных кадрах кластерные карты для лучших классификаций. Вверху справа при $kf=44,8$ получено 3 кластера, которые вполне соответствуют основным природным объектам: светлый тон - еще густой снежный покров, темный – хвойный лес, серое пятно справа соответствует оттаявшему участку поверхности (на исходном изображении он имеет красный цвет). Внизу классификации для $kf=16$ - 9 кластеров, и $kf=11,2$ –

54 кластера. Здесь видно, что снег уже не совсем сплошной, и появились облака.

Литература

1. W.Koontz, P.M.Narendra and K.Fukunaga. A graph theoretic approach to non-parametric cluster analysis, IEEE Trans.Comput.C-23. 1967. P. 936-944.
2. Сидорова В.С. Многомерная гистограмма и разделение векторного пространства признаков по унимодальным кластерам. Труды конференции GraphiCon'2005. 2005. С. 267-274.

Опыт разработки информационных технологий стохастической обработки и аудита электронных таблиц

И.Н. Сеницын, Э.Р. Корепанов, Д.Ф. Ильясов, Е.С. Агафонов
(Москва)

Введение

Электронная таблица (spreadsheet) является одним из основных видов приложений для автоматизации офисных задач и широко используется в различных прикладных областях. Интеграция электронных таблиц (ЭТ) с

языками программирования, позволила сделать из них средство быстрой разработки приложений для профессиональных разработчиков. Благодаря простой и удобной организации табличных вычислений, ЭТ часто используют не профессиональные пользователи, специалисты из других областей. Все это привело к тому, что ЭТ стали одним из самых распространенных программных продуктов, устанавливаемых на персональные компьютеры. Несмотря на то, что современные ЭТ превратились из простых редакторов таблиц в средства быстрой разработки приложений, до сих пор отсутствуют информационные технологии (ИТ) эффективной обработки данных в них (задача 1). Кроме того, качество большинства приложений ЭТ не соответствует важности обрабатываемой ими информации. Во многом это связано со значительным увеличением размерности современных ЭТ и недостаточным развитием ИТ аудита их качества (задача 2). Доклад посвящен развитию работ [3-7].

Основные результаты (задача 1)

Разработаны регулярные и стохастические ИТ обработки информации в современных ЭТ. Предполагается, что исходные данные организуются в таблицу с переменными размерами - *динамическую электронную таблицу* (ДЭТ). Особенностью предлагаемой стохастической обработки является использование статического и динамического факторного анализа, основанного на канонических разложениях (КР) случайных функций [8-10] Подробно рассматриваются следующие две технологии:

1. *ИТ онлайн обработки ДЭТ* для обработки данных по мере их ввода пользователем;
2. *ИТ пост обработки ДЭТ* для пакетной обработки данных в ДЭТ. Однако в отличие от ИТ онлайн обработки ДЭТ, данные обрабатываются только после их полного ввода. Преимуществом этой технологии является возможность производить более сложную обработку данных.

Основные результаты (задача 2)

Предложены две ИТ аудита ошибок в ЭТ, основанные на синтезе такого графического представления таблицы, при котором пользователю становятся очевидными ее ошибки. Такое графическое представление называется *визуальной моделью*, а процесс ее синтеза - *визуализацией*. Данные технологии позволяют пользователю автоматизированным способом выявлять ошибки в логике вычислений ЭТ. В основу первой ИТ положены методы визуализации логических регулярных (стохастических) областей, а в основу второй ИТ - методы визуализации логических регулярных (стохастических) классов. При разработке стохастических ИТ использованы методы представления пространств признаков посредством КР.

Особое внимание уделено ИТ экспертного анализа качества ЭТ, основанной на экспертных методах. Эта технология требует большего времени на свое исполнение, но при этом позволяет производить более всесторонний анализ качества ЭТ.

Заключение

Впервые разработано методическое и программное обеспечение ИТ обработки и аудита ошибок ЭТ.

Наиболее полное применение ИТ обработки и аудита получили в системе расчёта трудоёмкости эксплуатации информационно-телекоммуникационной системы Банка России. Спецификой данной задачи является ее направленность на обработку данных в таблицах и использование большого числа справочников, разной структуры. Предварительное макетирование программного комплекса с применением традиционных программных средств и баз данных, оказалась неудачной и выявило ряд проблем. Данные проблемы удалось решить путём использования ЭТ с применением технологий обработки и аудита. Реализация данной системы показала возможность быстрой разработки эффективных программных систем, ориентированных на обработку табличной информации, с использованием ЭТ.

ИТ обработки и аудита ЭТ были внедрены в англо-российской компании «Росинспекторат» в программном обеспечении (ПО) автоматизированного формирования отчётов по инспектированию нефтепогрузок и аудиту качества информации в отчётах. Разработанное ПО является приложением ЭТ которое ежедневно используется в подразделениях компании, и формируемые при помощи нее отчёты содержат 15-25 таблиц. Каждый отчёт по электронной почте пересылается в центральный офис и передаётся клиенту, заказчику услуг компании. Поэтому для компании очень важно иметь способы эффективной оценки качества электронных таблиц для выявления в них ошибок. В этих целях дополнительно была разработана методика экспертной оценки качества отчётов.

Литература

1. Kruck S.E., Sheetz S.D. Spreadsheet Accuracy Theory // Journal of Information Systems Education. - 2001. - Vol. 12. - No. 2. - P. 93-108.
2. Grossman T.A. Spreadsheet Engineering: A Research Framework // European Spreadsheet Risks Interest Group Symposium. 2002.
3. Пугачев В.С. Теория вероятностей и математическая статистика - М.: Наука, Физматлит, 1979 и 2002 (1-е и 2-е изд.).
4. Ильясов Д.Ф. Технология анализа качества информационных систем, построенных на основе электронных таблиц // Научно-технические технологии, - 2004. - №7. - С.88-94.
5. Сеницын И.Н., Будзко В.И., Ильясов Д.Ф. Методическое и

- программное обеспечение факторной идентификации // Труды III международной конференции «Идентификация систем и задачи управления» (SICPRO'04), 2004.-С. 1927-1940.
6. Будзко В.И., Ильясов Д.Ф., Сеницын И.Н., Рыков А.С. Многокритериальная оценка качества информационных систем в условиях неопределенности //Безопасность информационных технологий. -2004. - №1. - С.44-54.
 7. Сеницын И.Н., Сеницын В.И., Корепанов Э.Р., Ильясов Д.Ф. Современное состояние и приложения теории канонических представлений случайных функций // Математика в современном мире: материалы 2-й Российской научно-практической конференции 8-9 октября 2004 года. – Калуга: Изд. КГПУ им. К.Э. Циолковского, - 2004. – С. 43-52.
 8. Ильясов Д.Ф. Методы, алгоритмы и программное обеспечение анализа качества электронных таблиц // Труды IV международной конференции «Идентификация систем и задачи управления» (SICPRO'05), 2005.- С. 1164-1182.
 9. Ильясов Д.Ф., Сеницын И.Н. Информационные технологии стохастической обработки и аудита крупномасштабных электронных таблиц и их применение //Проблемы и методы информатики. II Научная сессия ИПИ РАН: Тезисы докладов. –М.: ИПИ РАН, 2005, с. 79-81.
 10. Пугачев В.С., Сеницын И.Н. Теория стохастических систем. - М.: Изд-во «Логос», 2000 (1-е изд.), 2004 (2-е изд.) [Англ. пер.: Stochastic Systems. Theory and Applications. - Singapore: World Scientific, 2001].

**Комбинирование потенциальных функций при
верификации личности по динамике подписи**
В.В. Сулимова, В.В. Моттль, О.С. Середин, О.В. Красоткина
(Тула, Москва)

Введение

Задача верификации личности по динамике подписи может быть сформулирована как проверка нулевой гипотезы о том, что рассматриваемая подпись действительно принадлежит автору, который называет свои идентификационные данные, против альтернативной гипотезы, состоящей в предположении, что рассматриваемая подпись является подделкой.

В данной работе предполагается, что каждая подпись вводится в компьютер непосредственно в процессе написания (online) и, в результате, оказывается представленной многокомпонентным дискретным сигналом, отражающим ее геометрические и динамические особенности.

Задача верификации личности по динамике подписи является ярким

примером широкого класса задач распознавания сигналов разной длительности, поскольку сигналы, полученные при написании подписи даже одним и тем же человеком, неизбежно будут иметь разную длину.

Одним из подходов к решению таких задач является беспризнаковый подход, к которому относятся такие методы обучения машин, как метод потенциальных функций [1] и вытекающий из него метод опорных векторов [2]. В их основе лежит понятие потенциальной функции $K(\omega', \omega'')$, определенной на множестве пар объектов $\omega', \omega'' \in \Omega$, значения которой могут быть интерпретированы как скалярное произведение в некотором гипотетическом линейном пространстве, минуя промежуточное понятие вектора признаков, априорное указание которого является проблематичным в связи с изначальным представлением объектов в виде сигналов разной длительности.

Потенциальные функции на множестве пар подписей

В данной работе потенциальные функции на множестве пар подписей $\omega', \omega'' \in \Omega$ строятся на основе парного выравнивания соответствующих дискретных сигналов [3]. Значение минимума сформулированного в работе [3] критерия поиска оптимальных парных соответствий между отсчетами сравниваемых сигналов обладает всеми свойствами метрики и может рассматриваться как расстояние между соответствующими подписями $\rho(\omega', \omega'')$. На основе данной метрики могут быть построены различные параметрические семейства потенциальных функций [4], например, семейство радиальных функций имеет вид

$$K(\omega', \omega'') = \exp\left[-\alpha \rho^2(\omega', \omega'')\right]. \quad (1)$$

В качестве альтернативного способа построения потенциальных функций можно предложить вероятностный принцип, описанный в работе [6].

Следует отметить, что построение потенциальных функций носит отчасти эвристический характер, поскольку существует целый ряд варьируемых параметров, относительно выбора которых не может быть высказано достаточно четких априорных предпочтений. Например, осуществление различной предварительной обработки сигналов (масштабирование, центрирование, сглаживание, выделение экстремальных точек, поворот подписей), назначение различных штрафов при парном выравнивании сигналов, выбор различных значений параметра α радиальной потенциальной функции (1), введение весовых коэффициентов при компонентах сигналов с целью акцентирования определенных характеристик подписи – все это приводит к формированию различных потенциальных функций. Каждая из них со своей стороны характеризует сходство пар подписей и при этом не представляется

возможным априорно определить, какая из предложенных функций наиболее адекватна данным учителя.

В связи с этим естественным является желание совместного использования различных потенциальных функций, причем так, чтобы окончательный их выбор осуществлялся автоматически в процессе обучения.

Комбинирование потенциальных функций

В работе [7] предлагается идея адаптивного обучения распознаванию образов, при котором происходит явное акцентирование потенциальных функций адекватных данным учителя и подавление неадекватных.

При этом предлагается рассматривать линейные пространства $\tilde{\Omega}_i$, порождаемые каждой потенциальной функцией $K_i(\omega', \omega'')$, $i = 1, \dots, n$ [4], заданной на множестве объектов $\omega \in \Omega$, $\Omega \subset \tilde{\Omega}_i$, $i = 1, \dots, n$ совместно, как их декартово произведение, а комбинированную потенциальную функцию в новом комбинированном линейном пространстве – в виде взвешенной суммы исходных функций $K_i(\omega', \omega'')$, $i = 1, \dots, n$ с весами r_i .

Описанная в [7] итерационная процедура обучения позволяет выбрать соответствующие весовые коэффициенты и дать конструктивную оценку функции, объективно разбивающей генеральную совокупность подписей $\hat{\Omega}$, $\Omega \subset \hat{\Omega}$ на два класса $y(\omega) : \hat{\Omega} \rightarrow g$, ($g = 1$, если подпись ω является оригинальной, и $g = -1$, если ω – подделка):

$$\hat{y}^{(k)}(\omega) = \sum_{j=1}^N \lambda_j^{(k)} g_j \sum_{i=1}^n r_i^{(k)} K_i(\omega_j, \omega) + b^{(k)} > 0 \text{ или } < 0, \quad (2)$$

где k -номер последней итерации при адаптивном обучении, $\lambda_j^{(k)}$ - множители Лагранжа, полученные при решении задачи квадратичного программирования на k -м шаге обучения, $b^{(k)}$ – константа, определение которой не составляет проблемы.

Результаты экспериментов

Эксперименты по комбинированию потенциальных функций проводились на базе данных подписей SVC2004. Для обучения было случайным образом отобрано 200 подписей 10-ти авторов (по 10 оригинальных подписей и 10 подделок каждого человека). Для проверки каждого решающего правила, использовались не участвовавшие в обучении 10 оригинальных подписей соответствующего автора, 10 подписей других авторов (случайные подделки) и 10 умышленных подделок. Было построено три радиальные потенциальные функции вида (1) с различными параметрами α и различными весами компонент сигналов, и две комбинированные потенциальные функции. Результаты

контроля приведены в таблице 1.

Таблица 1. Сравнительные результаты контроля верификации подписей для обычных и комбинированных потенциальных функций

Потенциальная функция	K_1	K_2	K_3	Комбинированная	
				с равными весами	с адаптивными весами
Суммарная ошибка, %	10	2	4	5.33	0.33

Работа выполнена при поддержке гранта INTAS (04-77-7347) и гранта Президента РФ для поддержки молодых ученых (МК-3173.2004.9).

Литература

1. Айзерман М.А., Браверман Э.М., Розоноэр Л.И. Метод потенциальных функций в теории обучения машин. М.: Наука, 1970, 384 С.
2. Вапник В.Н. Восстановление зависимостей по эмпирическим данным. М.: Наука, 1979, 447 С.
3. Дмитриев Д.А., Сулимова В.В., Моттль В.В. Измерение попарного несходства подписей для идентификации личности. //Труды международной научной конфер. ММТТ-16, Ростов-на-Дону, 2003г, т.4, С.37-40.
4. Моттль В.В. Метрические пространства, допускающие введение линейных операций и скалярного произведения.// Доклады Академии наук, 2003, том 388, № 3, С. 1-4.
5. Сулимова В.В., Моттль В.В. Идентификация личности по динамике подписи методом опорных векторов. //Труды международной научной конференции ММТТ-16, Ростов-на-Дону, 2003г, т.4, С.23-25.
6. Моттль В.В., Середин О.С., Сулимова В.В. Потенциальные функции для беспризнакового восстановления зависимостей на множествах сигналов и символьных последовательностей.//Искусственный интеллект -2'2004, С.140-144.
7. Моттль В.В., Середин О.С., Красоткина О.В. Комбинирование потенциальных функций при восстановлении зависимостей по эмпирическим данным.// Искусственный интеллект – 2'2004, С. 134-139.

Способы автоматического повышения точности формирования изображения бинокулярной системы технического зрения

М.И. Труфанов, В.С. Титов

(Курск)

В настоящее время интенсивно развиваются бинокулярные системы технического зрения (СТЗ), выполняющие функцию трехмерного зрения, используемые в автоматических системах управления различными процессами: от наблюдения за дорожным движением до распознавания изделий микроэлектроники. Качественные и эксплуатационные показатели функционирования СТЗ зависят от того, насколько близко приведены к эталонным параметры СТЗ, влияющие на точность формирования изображения.

Существующие способы приведения параметров СТЗ к эталонным, как правило, основаны на определении параметров по эталонному объекту, что затрудняет определение параметров и их последующую коррекцию в автоматическом режиме.

Предлагаемые способы [1, 2] позволяют в автоматическом режиме повысить точность формирования изображения и обеспечивают коррекцию фокусных расстояний оптико-электронных датчиков (ОЭД), расстояний между приемником изображения (ПИ) ОЭД и оптической системой (ОС) ОЭД, угловых отклонений положения ОЭД СТЗ, дисторсии ОС.

Коррекция фокусных расстояний оптико-электронных датчиков и расстояний от оптической системы до приемников изображения

Коррекция фокусных расстояний бинокулярной СТЗ заключается в приведении значений фокусных расстояний обоих ОЭД к равенству при одновременном сохранении максимально возможной резкости R изображения при текущих фокусных расстояниях [1]. Коррекция фокусных расстояний производится путем изменения расстояния L_0 между ОС и ПИ ОЭД, непрерывного определения резкости R изображения и приведения расстояния L_0 к значению

$$L' = \arg \max_{L_0 \in [L_{0\min}, L_{0\max}]} (R(L_0)),$$

установки максимальной резкости R изображения и приведения фокусных расстояний ОЭД к равенству, определяемому отношением периметров калибровочного объекта на кадрах, поступающих с разных ОЭД. Для автоматического выбора калибровочного объекта по изображению рабочей сцены применен математический аппарат нечеткой логики, позволяющий при априорной неопределенности параметров объектов на

изображении рабочей сцены выбрать калибровочный объект, удовлетворяющий заданным требованиям. Калибровочным объектом является объект рабочей сцены, определяемый лингвистической переменной «калибровочный объект» с функцией принадлежности (ФП)

$$\mu_f = \mu_g \wedge \mu_p \wedge \mu_c \wedge \mu_t$$

где μ_g – ФП термина «четкий»; μ_p – ФП термина «длинный периметр»; μ_c – ФП термина «центр кадра»; μ_t – ФП термина «неизменный».

Коррекция угловых отклонений положения оптико-электронных датчиков

К угловым отклонениям положения ОЭД относятся углы, характеризующие погрешности ориентирования главных оптических осей ОЭД: углы γ_1, γ_2 вращения ОЭД вокруг главных оптических осей ОЭД, определяющие соответствие горизонтальности строк обоих ОЭД; угол $\Delta\alpha$ между главными оптическими осями в горизонтальной плоскости; угол $\Delta\beta$ между главными оптическими осями в вертикальной плоскости.

Углы γ_1, γ_2 корректируются путем смещения направления наблюдения ОЭД в горизонтальной плоскости, определения углов γ_1, γ_2 по двумерным координатам на плоскости изображения калибровочного объекта до и после смещения направления наблюдения ОЭД и приведения углов к нулевым значениям [1]. Углы γ_i ($i=1, 2$) равны

$$\gamma_i = \arctg \left(\frac{h' - h}{l' - l} \right),$$

где l, l' – расстояния от левого края кадра до калибровочного объекта; h, h' – высоты от нижнего края кадра до калибровочного объекта.

Определение углов $\Delta\alpha, \Delta\beta$ основано на том, что при параллельных главных оптических осях ОЭД бинокулярного СТЗ объект, расположенный на достаточном удалении от СТЗ, будет иметь одинаковые координаты на кадрах изображения с разных ОЭД. Углы $\Delta\alpha, \Delta\beta$ определяются в соответствии с геометрической моделью ОЭД с передней плоскостью изображения при равных фокусных расстояниях f ОЭД, равных разрешающих способностях и равных геометрических размерах фоточувствительных сред ПИ по расхождению $\Delta x, \Delta y$ координат калибровочного объекта на изображениях с разных ОЭД

$$\Delta\alpha = \arctg \frac{\Delta x}{f}, \Delta\beta = \arctg \frac{\Delta y}{f},$$

где f – фокусное расстояние ОЭД, выраженное в пикселах.

После определения углов $\gamma_1, \gamma_2, \Delta\alpha, \Delta\beta$ производится изменение углового положения ОЭД, направленное на приведение угловых отклонений к

нулевым значениям.

Коррекция дисторсии оптических систем оптико-электронных датчиков

Коррекция искажений, вносимых дисторсией ОС ОЭД, осуществляется путем определения параметров дисторсии каждого ОЭД и последующего переноса всех точек кадра на рассчитанные по параметрам дисторсии позиции [2]. Параметрами дисторсии является ряд ее коэффициентов $k_1, k_2, \dots, k_j, \dots, k_n$.

Искажения, вызванные дисторсией, определяются по формулам

$$\Delta x_r = x(k_1 r^2 + k_2 r^4 + \dots + k_n r^{2n}), \Delta y_r = y(k_1 r^2 + k_2 r^4 + \dots + k_n r^{2n}),$$

где $(\Delta x_r, \Delta y_r)$ – отклонение точки изображения от ее истинного положения, $r = (x^2 + y^2)^{1/2}$ – расстояние от центра кадра до точки с координатами (x, y) .

Определение коэффициентов дисторсии производится по координатам калибровочного объекта. Наибольшая точность определения коэффициентов достигается, когда измеряются координаты калибровочного объекта при его наблюдении в центре вверху (или внизу) кадра и затем близко к краю слева или справа кадра. Осуществляется позиционирование ОЭД так, чтобы калибровочный объект занимал указанные положения, после чего рассчитываются коэффициенты дисторсии по определенным координатам калибровочного объекта до и после смещения наблюдения ОЭД. Коррекция дисторсии осуществляется смещением точек изображения в их истинные позиции, рассчитанные при известных коэффициентах k_1, \dots, k_n и определенных по изображению искаженных координатах точек.

Экспериментальные исследования разработанных способов повышения точности формирования изображения бинокулярной СТЗ показали большую по сравнению с известными способами точность коррекции параметров СТЗ (погрешности приведения значений параметров к эталонным снижены от 1,3 до 1,5 раз). При этом, в отличие от существующих, разработанные способы обеспечивают автоматическое повышение точности СТЗ, что расширяет область их применения.

Литература

1. Патент № 2250498 РФ, МКИ G06K9/32. Способ автоматической адаптивной трехмерной калибровки бинокулярной системы технического зрения и устройство для его реализации [Текст] / С.В. Дегтярев, В.С. Титов, М.И. Труфанов. – №2003105497/09; заявлено 25.02.2003; опубл. 20.04.2005, Бюл. №11. - 15с.
2. Titov, V.S. The method of automatic determination monochromatic aberration of vision's optical subsystem [Text]/ V.S. Titov, M.I. Truphanov // Second international conference «Information and Telecommunication

Technologies in Intelligent Systems». Proceedings. Spain. Barcelona, 2004.
- PP. 40 – 43.

Адаптивный морфологический алгоритм локализации объектов на изображении

И.И. Фаломкин Ю.П. Пытьев

(Москва)

Задача локализации объекта на изображении — одна из основных задач машинного зрения. Пусть известно изображение некоторой исходной сцены, и изображение сцены, полученной из исходной добавлением неизвестных объектов. Задача локализации состоит в нахождении той части поля зрения, на которой изображены добавленные к сцене объекты. Изображение исходной сцены будем называть фоновым, а изображение измененной сцены — изображением, предъявленным для анализа.

Решение такой задачи затрудняется тем обстоятельством, что между моментами получения фонового и предъявляемого для анализа изображений условия их регистрации могут существенно измениться. Кроме того, на практике, на анализируемом изображении присутствует шум, обусловленный неидеальностью регистрирующего прибора. Эти обстоятельства являются причиной того, что анализируемое изображение может кардинально отличаться от фонового даже в тех областях, в которых отсутствуют добавленные объекты.

В работах [1-3] представлены математические методы морфологического анализа изображений, позволяющие эффективно решать поставленную задачу в том случае, когда изображения добавленных объектов занимают относительно малую часть поля зрения. В противном случае, указанные методы позволяют надежно судить лишь о наличии или отсутствии новых объектов на изображении, но не позволяют локализовать их.

В работе [4] предложен алгоритм морфологической фильтрации изображений, позволяющий решать задачу локализации объектов и в том случае, когда объект занимает существенную часть поля зрения. Однако алгоритм морфологической фильтрации не позволяет локализовать «слабо текстурированные» объекты.

В работе [7] представлен итеративный морфологический алгоритм обладающий малым, по сравнению с алгоритмом морфологической фильтрации, временем выполнения, позволяющий локализовать «слабо текстурированные» объекты, но имеющий ограничение на максимальный размер добавленных объектов, которые не должны покрывать больше половины поля зрения.

В данной работе предлагается адаптивный морфологический алгоритм локализации неизвестного объекта на известном, с точностью до условий

регистрации, изображении фона, не имеющий ограничений на размер и текстурированность обнаруживаемых объектов и обладающий высокой помехозащищенностью. Предлагаемый алгоритм основан на идеях морфологической фильтрации [4] и наращивания области [6], и находит ту часть возможно искаженного изменением условий регистрации анализируемого изображения, которая не «искажена» по форме добавленными объектами. Адаптивный морфологический алгоритм является итеративным — на каждом шаге происходит уточнение оценки области, не содержащей добавленные объекты. Уточнение происходит путем добавления новой точки к текущей оценке. В том случае, когда такая точка не была найдена, оценка считается построенной.

Решение о наличии или отсутствии в некоторой точке x на анализируемом изображении нового объекта будем принимать, анализируя значения яркостей фонового и анализируемого изображений в некоторой окрестности D_x этой точки. Причем D_x будем выбирать так, чтобы фоновое изображение, будучи преобразованным найденными условиями регистрации, на D_x было наилучшим среди всех возможных окрестностей точки x приближением анализируемого изображения. Такое правило выбора анализируемой окрестности каждой точки позволяет повысить шумозащищенность алгоритма, и практически не исказить границы добавленных объектов [5].

Для сравнения предложенного алгоритма с морфологическим алгоритмом и алгоритмом морфологической фильтрации был проведен вычислительный эксперимент. Изображения, использованные в эксперименте, представлены на рисунке 1. Отметим, что условия регистрации фонового и анализируемых изображений существенно отличаются. Если принять время выполнения морфологического алгоритма за единицу, то время выполнения алгоритма морфологической фильтрации составило примерно 500 единиц, а адаптивного алгоритма — примерно 1500 единиц. Видно, что для решения задачи локализации объекта, занимающего малую часть поля зрения (рисунок 2), наиболее целесообразно применение морфологического алгоритма, поскольку он выполняется за наименьшее время и позволяет получить результат по качеству не уступающий результатам остальных алгоритмов. В том случае, когда добавленные объекты занимают существенную часть поля зрения (рисунок 3), наилучший результат показал адаптивный морфологический алгоритм. Отметим, что алгоритм морфологической фильтрации не смог правильно локализовать «слабо текстурированный» объект (вертикально стоящая книга).

Работа выполнена при финансовой поддержке РФФИ, грант №05-01--00615.



Рис. 1. Изображения, использованные в вычислительном эксперименте. Слева представлено фоновое изображение, справа – два анализируемых изображения.



Рис. 2. Локализация объекта, занимающего малую часть поля зрения.

Представлены результаты работы алгоритмов (слева направо): морфологический алгоритм, алгоритм морфологической фильтрации, адаптивный морфологический алгоритм.



Рис. 3. Локализация объекта, занимающего существенную часть поля зрения

Представлены результаты работы алгоритмов (слева направо): морфологический алгоритм [2], алгоритм морфологической фильтрации [4], адаптивный морфологический алгоритм [5].

Литература

1. Пытьев Ю.П. Морфологический анализ изображений // ДАН СССР, 1983, т.269, №5, с.1061-1064.
2. Пытьев Ю.П. Задачи морфологического анализа изображений // в сборнике статей “Математические методы исследования природных ресурсов Земли из космоса”. М.:Наука, 1984, с.41-82.
3. Pyt'ev Yu.P. Morphological image analysis // Pattern Recognition and Image Analysis, vol.3, №1, p.19-28, 1993.
4. Животников Г.С., Пытьев Ю.П., Фаломкин И.И. Об алгоритме фильтрации кусочно-постоянных изображений // Интеллектуальные системы. Москва, в печати.
5. Falomkin I.I., Pyt'ev Yu.P. Morphological algorithms of noise supression and object localization on image // Pattern Recognition and Image Analysis,

в печати.

6. Adams R., Bischof L. Seeded region growing // IEEE Transactions PAMI, vol.16, №6, p.641-647, 1994.
7. Животников Г.С., Пытьев Ю.П., Фаломкин И.И. Итеративный морфологический алгоритм локализации неизвестного объекта на изображении в реальном времени // Математические методы распознавания образов. Доклады 12-й Всероссийской конференции, 2005.

Трасе-преобразование в предварительной обработке изображений

Н.Г. Федотов, А.В. Моисеев, Л.А. Шульга
(Пенза)

Введение

В задачах распознавания изображений существенным является этап подготовки изображения к распознаванию (предварительная обработка изображений). Существенным преимуществом будет осуществление этого этапа в той же технике, что и формирование признаков изображения. Использование трасе-преобразования в формировании признаков изображений показано в [1], [2]. В данной статье показывается применение трасе-преобразования в предварительной обработке изображений.

Рассматриваются следующие задачи: сегментация, определение числа объектов, определение метрических характеристик. В результате подготовки изображения к распознаванию получаем необходимый материал для дальнейшего формирования признаков изображений. Тем самым, предлагается выполнение предобработки изображения и формирование признаков изображения в одной технике, что до настоящего момента практически не встречалось.

Трасе-преобразование

Пусть $F(x, y)$ функция изображения на плоскости (x, y) . Определим на плоскости прямую $l(\varphi, \rho, t)$, которая определяется параметрами φ и ρ :

$$x \cdot \cos \varphi + y \cdot \sin \varphi = \rho,$$

параметр t определяет точку на прямой. Определим функцию двух аргументов $g(\varphi, \rho) = \mathbf{T}(F \cap l(\varphi, \rho, t))$ как результат действия функционала \mathbf{T} при фиксированных значениях переменных φ и ρ .

Первоначальному изображению F соответствует новое изображение (можно трактовать результат действия функционала \mathbf{T} как изображение,

характеристики которого в точке (φ, ρ) — его трасе-образ).

Признак (триплетный признак) получается путем преобразования полученного трасе-образа двумя функционалами, которые действуют на переменные ρ и φ . Таким образом, признак есть композиция трех функционалов $\mathbf{П}(F) = \mathbf{\Theta} \circ \mathbf{Р} \circ \mathbf{Т}(F \cap l(\varphi, \rho))$, где φ, ρ — нормальные координаты сканирующей прямой $l(\varphi, \rho)$, а F — функция изображения распознаваемого объекта, функционалы $\mathbf{\Theta}$, $\mathbf{Р}$ и $\mathbf{Т}$ действуют по переменным φ, ρ, t соответственно.

Триплетные признаки широко применялись в задачах биологии [3], биометрии [2], технической дефектоскопии [4].

Нелинейная фильтрация изображений на основе трасе-преобразования

Трасе-преобразование является эффективным методом сегментации объектов на изображении и определения числа объектов. Строение трасе-образа таково, что каждому объекту на исходном изображении соответствует синусоподобное изображение на образе. На рис. 2а приведено изображение, состоящее из трех объектов. Трасе-матрица изображения, состоящего из нескольких объектов, имеет характерный вид, показанный на рис. 2б.




Рис. 1. Изображение нескольких объектов: а) исходное изображение; б) трасе-образ.

Число объектов на изображении равно максимальному числу отрезков, высекаемых из трасе-образа прямой, параллельной оси ρ . Если определить функционал $\mathbf{Р}$ как число пересечений образа $g(\varphi, \rho)$ прямой $\varphi = \varphi_0$, а функционал $\mathbf{\Theta}$ как максимум по переменной φ , то получим триплетный признак, значение которого есть число объектов на изображении.

Сегментацию объектов нетрудно провести, если заметить, что каждая точка образа (φ, ρ) соответствует прямой $l(\varphi, \rho)$. Замкнутая внутренняя область трасе-образа $g(\varphi, \rho)$, в которой значения функции равны нулю, определяет множество сегментирующих прямых l , с нормальными координатами (φ, ρ)

$$l = \{(x, y) : x \cos \varphi + y \sin \varphi = \rho\}.$$

Проведя по одной прямой из каждой внутренней области нулевых значений трассе-образа, получим разбиение изображения на множество изображений, каждое из которых содержит не более одного объекта.

Важным является определение метрических характеристик изображения. Триpletные признаки, имеющие конкретный геометрический смысл, могут рассматриваться не только как признаки, но и как предварительная информация об изображении.

Пусть $n(\varphi, \rho)$ — функция числа пересечений изображения F прямой $l(\varphi, \rho)$. Определим функционал \mathbf{T} как функцию n , функционал \mathbf{P} определим как интеграл по переменной ρ в пределах ее изменения. Определяя функционал $\mathbf{\Theta}$ как максимум по переменной φ , получим в качестве tripletного признака диаметр объекта на изображении.

Если заменить в рассмотренной трехзвенной структуре функционал \mathbf{T} на следующий:

$$\mathbf{T}(F \cap l) = \int_{F \cap l \neq \emptyset} f(\varphi, \rho, t) dt,$$

а функционал $\mathbf{\Theta}$ взять как первый момент, то получим площадь исследуемого объекта.

Рассмотрение функционалов $\mathbf{T} = n(\varphi, \rho)$, \mathbf{P} — число пересечений образа $g(\varphi, \rho)$ прямой $\varphi = \varphi_0$ и в качестве $\mathbf{\Theta}$ — минимум функции по переменной ρ , позволяет определить расположение объектов на одной прямой. Если tripletный признак равен 1, то объекты расположены вдоль одной прямой.

Заключение

Рассмотренная в статье техника имеет неоспоримое преимущество перед имеющимися методами. Предварительная обработка выполняется в той же технике, что и получение признака изображения. Богатство реализаций трассе-преобразований позволяет добиваться решения самых разнообразных задач предварительной обработки изображений.

Работа выполнена при финансовой поддержке Human Capital Foundation

Литература

1. Федотов Н.Г. Теория признаков распознавания образов, основанная на стохастической геометрии // Искусственный интеллект, 2000, №2. С.207-211
2. Федотов Н.Г., Рой А.В. Анализ биологических микрообъектов с помощью методов стохастической геометрии // Измерительная техника, 2004, N 4, С.61-64.

3. Федотов Н.Г., Кадыров А.А. Признаки изображений, не зависящие от перемещений и линейных деформаций // Измерительная техника, 1996, №4, с. 13-16.
4. Федотов Н.Г., Никифорова Т.В. Техническая дефектоскопия на основе новой теории распознавания образов // Измерительная техника. – 2002. – №12. – с. 27–31.

Двойственное трасе-преобразование в предварительной обработке изображений

Н.Г. Федотов, А.В. Моисеев, Л.А. Шульга
(Пенза)

Введение

В задачах распознавания образов традиционно выделяют несколько этапов: подготовка к распознаванию (предварительная обработка), формирование признаков, решающая процедура. Реализация первых двух этапов чаще всего различна и существенно зависит по общепринятому мнению от интуиции проектировщика распознающей системы.

В настоящей статье рассматривается новое применение методов стохастической геометрии [1]. Ключевым элементом теории признаков распознавания, основанной на стохастической геометрии, является трасе-преобразование, связанное со сканированием изображений по сложным траекториям [1, 2]. Показано, что трасе-преобразование является не только источником формирования триплетных признаков, но и средством предварительной обработки изображений: уменьшения зашумленности, сглаживания, полигональной аппроксимации. Реализация предварительной обработки изображений в той же технике, что и формирование признаков, позволяет повысить быстродействие распознающих систем, так как предварительная обработка изображений и формирование признаков осуществляется в одном такте работы сканирующей системы.

В статье вводится новый математический аппарат – двойственное трасе-преобразование. Двойственное трасе-преобразование позволяет осуществить нелинейную фильтрацию с целью предварительной обработки изображений.

Двойственное трасе-преобразование

Пусть $F(x,y)$ – функция изображения на плоскости (x,y) . Определим на плоскости сканирующую прямую $l(\varphi, \rho, t)$ (φ, ρ нормальные координаты):

$$x \cdot \cos \varphi + y \cdot \sin \varphi = \rho, \quad (1)$$

параметр t задает точку на прямой. Определим функцию двух аргументов $g(\varphi, \rho) = \mathbf{T}(F \cap l(\varphi, \rho, t))$ как результат действия функционала \mathbf{T} при

фиксированных значениях переменных φ и ρ . Значения функции F на прямой $l(\varphi, \rho)$ плоскости (x, y) порождают значение функции $g(\varphi, \rho)$ в точке плоскости (φ, ρ) по правилу **T**. Преобразуем выражение (1):

$$\sqrt{x^2 + y^2} \left(\frac{x}{\sqrt{x^2 + y^2}} \cos \varphi + \frac{y}{\sqrt{x^2 + y^2}} \sin \varphi \right) = \rho,$$

$$A \cos(\theta - \varphi) = \rho, \quad (2)$$

где $A = \sqrt{x^2 + y^2}$ и $\theta = \arccos \frac{x}{\sqrt{x^2 + y^2}}$.

На основании (2) можно говорить, что значение функции $F(x, y)$ в точке (x, y) порождает значения функции g на синусоиде (2), в плоскости (φ, ρ) .

Рассмотрим функционал $\mathbf{T}'(g \cap s(x, y, t))$, где $s(x, y, t)$ – синусоида (2), определяемая параметрами x и y , а t определяет точку на синусоиде. Определим функцию двух аргументов $F'(x, y) = \mathbf{T}'(g \cap s(x, y, t))$ как результат действия функционала \mathbf{T}' при фиксированных x и y . Преобразование \mathbf{T}' назовем двойственным трасе-преобразованием в силу двойственности соотношений (1) и (2).

Если последовательно выполнить прямое, а затем двойственное трасе-преобразования, то получим преобразование функции изображения $F(x, y)$ в функцию изображения $F'(x, y)$:

$$F' = \mathbf{T}'(\mathbf{T}(F \cap l(\varphi, \rho, t)) \cap s(x, y, t)).$$

Выбор конкретных реализаций функционалов \mathbf{T} и \mathbf{T}' позволяет получить преобразование с заданными свойствами (в том числе и тождественное).

В зависимости от вида прямого и двойственного трасе-преобразований возможно осуществить предварительную обработку изображений с целью уменьшения зашумленности изображений, сглаживания, полигональной аппроксимации и выделения контура или выпуклой оболочки.

Нелинейная фильтрация изображений

Определим функционал \mathbf{T} (прямое преобразование) по формуле

$$\mathbf{T}(F \cap l) = \int_{F \cap l \neq \emptyset} f(\varphi, \rho, t) dt. \quad (3)$$

При дискретной реализации преобразования функционал \mathbf{T}

вычисляется как сумма интенсивностей всех точек изображения F , лежащих на сканирующей прямой l .

Функционал \mathbf{T}' (двойственный функционал) определим так:

$$\mathbf{T}'(g \cap s) = \begin{cases} 1, & \text{если для всех } t \in s \Rightarrow g(\varphi, \rho) > \delta \\ 0, & \text{если существует } t \in s : g(\varphi, \rho) \leq \delta \end{cases} \quad (4)$$

Изображение F' , полученное применением функционала \mathbf{T}' при нулевом пороге $\delta = 0$, и будет представлять собой результат полигональной аппроксимации исходного изображения F (рис. 1б).

Выполняя преобразования (3) и (4) при положительном значении δ мы получим сглаживание контура выпуклой фигуры на изображении (рис. 1в).



Рис. 1. Полигональная аппроксимация и сглаживание: а) исходное изображение; б) результат полигональной аппроксимации; в) результат полигональной аппроксимации со сглаживанием контура; г) выпуклая оболочка

Модифицируем функционал \mathbf{T}' , определив его следующим образом:

$$\mathbf{T}(g \cap s) = \begin{cases} 1, & \text{если для всех } t \in s \ g(\varphi, \rho) > \delta \text{ и существует } t, \text{ такое,} \\ & \text{что для любой окрестности точки } t \text{ существует } g(\varphi, \rho) = 0, \\ 0, & \text{в противном случае} \end{cases} \quad (5)$$

Функционал \mathbf{T} зададим выражением (3). Выполняя трасе-преобразования с помощью функционалов \mathbf{T} и \mathbf{T}' , получим контурное изображение выпуклой оболочки фигуры (рис. 1г). Использование ненулевого порогового значения δ позволяет добиться сглаживания контура выпуклой оболочки.

В реальности распознающая система всегда оперирует с изображениями, получение которых было обусловлено внесением в них определенных искажений (например, пространственных деформаций, различных видов шума и т.п.). Наличие шума усложняет задачу, стоящую перед системой распознавания. Поэтому разработка методов подавления шума (особо при условии возможного совмещения с вычислением признаков) актуальна.

Если выбрать функционал \mathbf{T} , который придавал бы больший вес тем элементам трасе-преобразования, которые соответствуют прямым, пересекающим исходную фигуру, и снижал бы веса остальных элементов

trase-преобразования. Примером функционала T может служить максимальная длина отрезка, получаемого пересечением изображения сканирующей прямой. В качестве функционала T' можно использовать определение (5) при пороговом значении $\delta > 0$. Подбирая пороговое значение δ , мы можем добиться требуемого уровня подавления шума.

Более совершенные методы подавления шума могут быть разработаны путем усложнения функционала T . Доказали эффективность функционалы с использованием логарифмических и степенных зависимостей.

Работа выполнена при финансовой поддержке Human Capital Foundation

Литература

1. Федотов Н.Г. Методы стохастической геометрии в распознавании образов. – М.: Радио и связь, 1990.
2. Fedotov N.G. The Theory of Image Recognition Features Based on Stochastic Geometry // Pattern Recognition and Image Analysis. – 1998. – Vol. 8. – №. 2. – pp. 264–267.

Анализ свойств признаков распознавания, основанных на стохастической геометрии, при различных вариантах сканирования изображений

Н.Г. Федотов, Л.А. Шульга, А.В. Моисеев, А.С. Кольчугин
(Пенза)

Введение

В статье [4] настоящего сборника обосновывается целесообразность сканирования со случайными параметрами по сравнению с детерминированными при распознавании на основе триплетных признаков.

В связи с этим возникает вопрос о сохранении свойств инвариантности и сензитивности признаков распознавания при сканировании изображений со случайными параметрами. Сохранение инвариантности, в общем, очевидно и следует из того, что вероятностная мера при генерации множества сканирующих линий (мера Лебега) строится на основе кинематической меры множества прямых [1]. Сохранение сензитивности признаков распознавания при сканировании со случайными параметрами далеко не тривиально. Исследованию этого вопроса посвящена настоящая статья.

Свойства триплетных признаков

Структура признака распознавания есть композиция трех функционалов Θ, P, T , действующих, соответственно, по переменным φ , ρ и t [4]:

$$\Pi(F) = \Theta(h(\varphi)) = \Theta \circ \mathbf{P}(g(\varphi, \rho)) = \Theta \circ \mathbf{P} \circ \mathbf{T}(f(\varphi, \rho, t)).$$

Для надежного распознавания изображений независимых от перемещений, поворотов и линейных деформаций объектов используются инвариантные признаки. Мы называем функционал Ξ инвариантным, если $\Xi(u \circ (x + b)) = \Xi u$ для всех $b \in R$.

Теоретические исследования свойств инвариантности признаков основаны на теореме, доказанной ранее Н.Г. Федотовым, А.А. Кадыровым.

Теорема: если функционалы $\Theta, \mathbf{P}, \mathbf{T}$ инвариантны к сдвигу, т.е. если $\mathbf{T}(u(t + b)) = \mathbf{T}(u(t))$ для всех чисел b , $\mathbf{P}(u(\rho + b)) = \mathbf{P}(u(\rho))$ для всех чисел b , $\Theta(u(\varphi + b)) = \Theta(u(\varphi))$ для всех чисел b , то триплетный признак $\Pi(F) = \Theta \circ \mathbf{P} \circ \mathbf{T}(f(\varphi, \rho, t))$ независим от группы движений образа.

Однако, в робототехнике для точного позиционирования инструмента, для многих задач аэрокосмических исследований требуется определять параметры перемещения объектов. Для этого используются чувствительные признаки, позволяющие определять параметры движения и линейных деформаций изображений. Мы называем функционал Z чувствительным, если $Z(u \circ (x + b)) = Zu - b$ для всех $b \in R$.

Приведем некоторые примеры функционалов двух видов:

Инвариантные функционалы:

1. Максимальное значение функции.
2. Количество экстремумов функции.
3. Общая вариация функции.
4. Стандартная евклидова норма функции.
5. Любой функционал, определяемый распределением значений функции.

Чувствительные функционалы:

1. Стандартный центр тяжести масс, вычисленный следующим образом:

$$Zg = \frac{\int pg(p)dp}{\int g(p)dp} \text{ (пример диаметрального функционала).}$$

2. Фаза второй гармоники Фурье функции.
3. Абсолютное значение коэффициента Фурье третьей гармоники.
4. Теоретико-вероятностная медиана.

Для каждого из трех функционалов можно подобрать десятки разных конкретизаций, удовлетворяющих требуемым условиям. Следовательно, без больших вычислительных затрат можно генерировать тысячи новых признаков, инвариантных или чувствительных к движениям образа. Это доказывает ценность рассмотренных подходов для задач распознавания образов с множественной структурой классов (распознавание иероглифов или текстур).

**Исследование сохранения свойства сензитивности признаков
распознавания при сканировании со случайными параметрами**

Рассмотрим получение триплетных признаков на основе кинематической меры [1].

Для расширения получаемых признаков рассмотрим интегрирование некоторой функции $f(\varphi, \rho, t)$ изображения распознаваемого объекта F :

$$\mathbf{\Pi}(F) = \int_F f(\varphi, \rho, t) d\varphi d\rho dt .$$

Представим кратный интеграл как последовательный

$$\mathbf{\Pi}(F) = \int_0^{2\pi} d\varphi \int_0^{+\infty} d\rho \int f(\varphi, \rho, t) dt .$$

Это представление позволяет рассматривать $\mathbf{\Pi}(F)$ как триплетный признак.

Введем в рассмотрение на множествах изменения φ и ρ вероятностные распределения путем определения функций распределения $G(\varphi)$ и $S(\rho)$. В этом случае $\mathbf{\Pi}'(F) = \int_0^{2\pi} dG(\varphi) \int_0^{+\infty} dS(\rho) \int f(\varphi, \rho, t) dt$ так же есть признак, полученный с использованием сканирования со случайными параметрами.

Если вероятности распределения $G(\varphi)$ и $S(\rho)$ таковы, что существуют функции плотности распределения, то

$$\mathbf{\Pi}'(F) = \int_0^{2\pi} g(\varphi) d\varphi \int_0^{+\infty} s(\rho) d\rho \int f(\varphi, \rho, t) dt = \int_0^{2\pi} d\varphi \int_0^{+\infty} d\rho \int g(\varphi) s(\rho) f(\varphi, \rho, t) dt .$$

По своей структуре признак $\mathbf{\Pi}'(F)$ аналогичен $\mathbf{\Pi}(F)$. Отличие в том, что функция f умножается на функции плотности распределения $g(\varphi)$, $s(\rho)$.

Если рассматривать техническое устройство, то изменение параметра ρ конечно; на множествах изменения φ и ρ можно задать равномерные распределения. В этом случае

$$\mathbf{\Pi}'(F) = \frac{1}{2\pi\Delta} \int_0^{2\pi} d\varphi \int_0^{\Delta} d\rho \int f(\varphi, \rho, t) dt = \frac{1}{2\pi\Delta} \mathbf{\Pi}(F) ,$$

где Δ – ширина изменения параметра ρ .

Значит, если признак $\mathbf{\Pi}(F)$ обладает некоторым свойством, например, сензитивностью, то и признак $\mathbf{\Pi}'(F)$ так же обладает этим же свойством.

Следует сказать, что в общем случае вероятностные распределения могут быть произвольными. Подбор функций $g(\varphi)$ и $s(\rho)$ может быть осуществлен таким образом, что функция изображения $f^* = g \cdot s \cdot f$ сохранит свойства признака $\Pi(F)$ при организации сканирования со случайными параметрами.

Заключение

В статье доказано, что свойства сензитивности признаков распознавания по отношению к движению и линейным деформациям объекта сохраняется при сканировании со случайными параметрами. Следовательно, сензитивные признаки можно использовать для определения параметров движения (перемещения, поворотов) и линейных деформаций объектов (в частности, масштабных изменений).

Работа выполняется при поддержке гранта РФФИ (проект №05-01-00991).

Литература

1. Федотов Н.Г. Методы стохастической геометрии в распознавании образов.— М: Радио и связь.— 1990.
2. Nikolay G. Fedotov, Lyudmila A. Shulga. Feature Generation and Stochastic Geometry, // Proc. of the 4th International Workshop on Pattern Recognition in Information Systems, PRIS 2004, Porto, Portugal, April 2004, p. 169-175.
3. Nikolay G. Fedotov, Lyudmila A. Shulga. New Ways to Form Features for Pattern Recognition on the Basis of Stochastic Geometry // Proc. of the 12th Scandinavian conf. on Image Analysis, SCIA-2001, 11-14 June, Bergen, Norway. — Grafik produksion: Geo Grafik as Bergen, 2001. — Vol.1 — p.686-690.
4. Федотов Н.Г., Шульга Л.А., Моисеев А.В., Кольчугин А.С. Сканирование со случайными параметрами как источник повышения быстродействия систем распознавания, основанного на методах стохастической геометрии. // См. настоящий сборник.

Сканирование со случайными параметрами как источник повышения быстродействия систем распознавания, основанного на методах стохастической геометрии

Н.Г. Федотов, Л.А. Шульга, А.В. Моисеев, А.С. Кольчугин

(Пенза)

Введение

Методы стохастической геометрии позволяют формировать большое количество признаков нового класса – триплетных признаков, имеющих структуру в виде композиции трех функционалов и получать их в режиме автоматической компьютерной генерации [3].

В распознавании образов существует обширный класс задач, когда задача распознавания совмещена с задачей поиска объектов (в аэрокосмических исследованиях, динамической диагностике в технике и т.д.). При решении этих задач появляются преимущества при сканировании по траекториям со случайными параметрами. Как показано в [2] в этом случае улучшается соотношение надежность распознавания – быстродействие в распознающих системах (по сравнению с детерминированной разверткой). Сканирование со случайными параметрами повышает гибкость и универсальность распознавания изображений со случайной текстурой (типичный пример – изображения из области нанотехнологий). Статья посвящена формированию признаков распознавания при сканировании изображений со случайными параметрами с целью расширения круга решаемых задач.

Трасе-преобразование изображений при сканировании со случайными параметрами

Пусть $F(M)$ функция изображения на плоскости. Определим на плоскости прямую $l(\varphi, \rho, t)$, которая задается параметрами φ и ρ ; параметр t определяет точку на прямой. Определим функцию двух аргументов $g(\varphi, \rho) = \mathbf{T}(F \circ l(\varphi, \rho, t))$ как результат действия функционала \mathbf{T} при фиксированных значениях переменных φ и ρ .

При проектировании распознающих систем используют дискретное трасе-преобразование. Параметры сканирующей прямой образуют два множества $A = \{\rho_1, \dots, \rho_m\}$, $\Omega = \{\varphi_1, \dots, \varphi_n\}$. Результат действия функционала \mathbf{T} есть матрица с элементами $t_{ij} = \mathbf{T}(F \circ l(\varphi_j, \rho_i, t))$. Детерминированное сканирование однозначно определяет все элементы матрицы.

Для организации сканирования со случайными параметрами на множествах A и Ω задаются вероятностные распределения

$$\xi = (\xi_1, \xi_2, \dots, \xi_n), \quad \sum_i \xi_i = 1; \quad \eta = (\eta_1, \eta_2, \dots, \eta_m), \quad \sum_j \eta_j = 1.$$

Выбирая параметры сканирования случайным образом на основе заданных распределений, получаем матрицу случайных величин T_{ij} , $T_{ij} = 0$ с вероятностью $(1 - \xi_i \eta_j)$ и $T_{ij} = t_{ij}$ с вероятностью $\xi_i \eta_j$. Распределение величины T_{ij} определяется случайностью изображения F и распределениями ξ, η .

Формирование признаков распознавания

Трасе-преобразование есть основа получения интегральных признаков, которые можно представить в виде последовательного действия трех

функционалов [3]. В [2] рассмотрено сканирование решетками фигур K_0 , которые получаются как результат всех движений, переводящих решетку фундаментальных областей $\alpha_0, \alpha_1, \alpha_2, \dots$ в себя [1]. Дискретный вариант получения триплетных признаков есть результат сканирования изображения K решеткой параллельных прямых. В [2] показано, что в этом случае интеграл

$$I = \int_{K \cap K_0 \neq \emptyset} f(K \cap K_0) dK, \quad (1)$$

где dK – кинематическая мера относительно K , равен интегралу от суммы $I = \int \sum_{\alpha_0}^i f(T_i K_0 \cap K) dK$, T_i – движение, переводящее α_i в область α_0 .

На последовательности конгруэнтных областей $\alpha_0, \alpha_1, \dots, \alpha_n, \dots$ зададим вероятностное распределение $P(n)$. В этом случае (1) следует заменить оценкой $I' = \int \sum_{\alpha_0}^i f(T_i K_0 \cap K) P(i) dK$.

Пусть функция $f(K_0 \cap K)$ есть число точек пересечения фигур K_0 и K . Тогда интеграл I , как показано в [2], равен $4l(a-l)$, l – периметр фигуры K , а a – расстояние между прямыми сканирования ($l < a$). a есть случайная величина с распределением $P(n)$, поэтому интеграл (1) оценивается величиной

$$\begin{aligned} I' &= \int \sum_{\alpha_0}^i f(T_i K_0 \cap K) P(i) dK = \sum_i \int_{\alpha_0} f(K_0 \cap T_i^{-1} K) dK P(i) = \\ &= \sum_i 4l(a_i - l) P(i) = 4l(Ma - l), \end{aligned} \quad (2)$$

Ma – математическое ожидание случайной величины a для распределения $P(n)$, заданного на множестве конгруэнтных областей $\alpha_0, \alpha_1, \alpha_2, \dots$.

Фигура K является случайной и параметр l есть случайная величина, характеризующая K . В этом случае, как доказано в [2] величина (1) равна

$$I = 4Ml(a - Ml). \quad (3)$$

Если сканирование происходит со случайными параметрами, тогда учитывая (2) и (3), получим следующий результат $I' = 4Ml(Ma - Ml)$.

Ошибки измерения признаков распознавания возникают в силу случайности изображения и случайности прямых сканирования. При

детерминированном сканировании дисперсия оценки числа I при N сканирующих прямых, согласно [2], равна $\sigma^2 = \sigma^2[n]/N$. Данная дисперсия определяется случайностью изображения. В [2] показано, что дисперсия случайной величины n , числа пересечений образа со сканирующей фигурой, определяется размерами области сканирования.

При случайном сканировании из N имеющихся прямых выбирается L . Определяя последовательно, выбирать прямую или нет, будем иметь дело с биномиальным распределением с параметром $q = \frac{1}{N}$. Так как N велико – q мало; биномиальное распределение аппроксимируется распределением Пуассона с параметром $\lambda = Lq = \frac{L}{N}$. Если размер изначальной ячейки a , то $a_i = (m+1)a$, где m – число последовательно не выбранных прямых, есть случайная величина, распределенная по геометрическому закону.

В этом случае дисперсия величины I' определяется, в том числе, дисперсией величины a_i . Равенство (2) запишется в виде

$$I' = \sum_m 4l(a(m+1)P_L(m) - l) \approx 4la \sum_m (m+1) \frac{\lambda^m e^{-\lambda}}{m!} - 4l^2 = 4l(a-l) + 4la\lambda$$

За счет уменьшения числа сканирующих прямых величина σ^2 увеличится в $\frac{N}{L}$ раз при детерминированном сканировании изображений. При случайном сканировании мы должны учесть дисперсию распределения Пуассона, которая равна $\lambda = \frac{L}{N}$. Значит, при сканировании изображений со случайными параметрами итоговая дисперсия сохранится на уровне σ^2 .

Заключение

На основе выше изложенного следует, что формирование признаков распознавания при сканировании со случайными параметрами уменьшает дисперсию оценки признака без увеличения числа сканирующих прямых. Это ведет к повышению гибкости и быстродействия распознающих систем.

Работа выполнена при поддержке гранта РФФИ (проект №05-01-00991)

Литература

1. Сантало Л. Интегральная геометрия и геометрические вероятности: Пер. с англ. – М.: Наука, 1983. – 358 с.
2. Федотов Н.Г. Методы стохастической геометрии в распознавании образов.– М: Радио и связь. – 1990.
3. Nikolay G. Fedotov, Lyudmila A. Shulga. New Ways to Form Features for Pattern Recognition on the Basis of Stochastic Geometry // Proceedings of the 12th Scandinavian conference on Image Analysis, SCIA-2001 11th-14th

Формирование меры схожести кватернионных сигналов при распознавании 3D

Я.А. Фурман, Р.Г. Хафизов

(Йошкар-Ола)

Характерное для последнего периода интенсивное развитие математических методов позволяет достаточно эффективно решать задачи обработки и распознавания 3D изображений на основе анализа меры их взаимной схожести. Если $\{A_l\}_{0,M-1}$, $A_l = \{a_l(n)\}_{0,s-1}$, алфавит из M эталонных сигналов в виде совокупности n векторов размерности S , а η_l – мера схожести распознаваемого зашумленного со случайными параметрами сигнала $B = \{b(n)\}_{0,s-1}$ с эталонным сигналом A_l , то решение выносится в пользу класса с максимальным значением данной меры. При использовании векторных моделей нормированных сигналов естественной мерой их схожести является скалярное произведение $\eta_l = (B, A_l)$, $l = 0, 1, \dots, M-1$. Алгоритмически значение такой меры формируется в виде пикового значения выходного сигнала согласованного

фильтра $\eta_l(d) = \sum_{n=0}^{s-1} b(n)a_l^*(n-d+s-1)$, которое образуется в момент

$d = s-1$ и равно $\eta_l(s-1) = \sum_{n=0}^{s-1} b(n)a_l^*(n)$. В настоящее время

достаточно подробно исследована согласованная фильтрация одномерных и двумерных сигналов. Принципиально также отсутствуют затруднения, связанные с согласованной фильтрацией и трехмерных сигналов. Но практически переход к обработке и распознаванию 3D изображений, заданных моделями в виде вещественных векторов, осложняются неинвариантностью алгоритмов к параметрам вращения этих изображений и трудностями получения компактных и достаточно простых формул для принятия решения о классе распознаваемого изображения. Перспективным в этом в этом плане является задание 3D векторов с помощью кватернионов. Преимущества кватернионных моделей 3D изображений заключается в чрезвычайно простом выполнении вращения 3D вектора и, естественно, изображения в целом, а также в том, что мера схожести кватернионных сигналов в виде их скалярного произведения из-за наличия весомой мнимой части более информативна, чем скалярное произведения

вещественных 3D векторов.

В работах [1,2,3,4] было введено понятие скалярного произведения кватернионов, кватернионных сигналов (КТС), получен ортогональный базис $\{\mathbf{Q}_m\}_{0,s-1}$ из элементарных кватернионов сигналов (ЭКС)

$$\mathbf{Q}_m = \Gamma_m(1 + j), \text{ где } \Gamma_m = \left\{ \exp\left\{i \frac{2\pi}{s} mn\right\} \right\}_{0,s-1} - \text{элементарный}$$

комплекснозначный сигнал. получены спектры и корреляционные функции КТС, а также рассмотрен алгоритм согласованной фильтрации для принятия решения о классе зашумленного изображения.

Дальнейшие исследования обнаружили определенные странности поведения кватернионных фильтров по сравнению с их вещественными и комплекснозначными аналогами.

Цель данного доклада заключается в изложении результатов полного исследования работы кватернионных согласованных фильтров. Отличие их свойств от обычных фильтров вызвано некоммутативностью операции перемножения двух кватернионов. Следствием этого является тот факт, что операция кватернионного сопряжения ЭКС \mathbf{Q}_m из ортогонального базиса $\{\mathbf{Q}_m\}_{s-1}$ приводит к появлению КТС \mathbf{Q}_m^* , который не входит в состав этого базиса. В результате ЭКС \mathbf{Q}_m перестает быть собственным сигналом фильтра. Хотя спектр ЭКС \mathbf{Q}_m состоит из одной ненулевой компоненты, однако реакция фильтра на такой сигнал представляет собой сигнал с двумя ненулевыми гармониками: одна гармоника на частоте m исходного сигнала, другая на зеркальной частоте $s - m$. В связи с этим нарушаются традиционные понятия о частотном коэффициенте передачи фильтра и об его связи с импульсной характеристикой.

В результате проведенного анализа получены соотношения для выходного сигнала кватернионного согласованного фильтра и его спектра, а также для его локальных частотных и пространственных характеристик.

Работа выполнена при финансовой поддержке РФФИ, (проект № 04-01-00243)

Литература

1. Furman Ya.A. Processing of Quaternion Signals Specifying Spatially Located Group Point Objects //Pattern Recognition and Image Analysis, Vol.12, No.2, 2002, pp.175-193.
2. Фурман Я.А. Хафизов Д.Г. Распознавание групповых точечных объектов в трехмерном пространстве// Автометрия.- 2003.- №1.-С. 3-18.

3. Введение в контурный анализ и его приложения к обработке изображений и сигналов/ Под ред. Я.А. Фурмана. – М.: Физматлит, 2002.
4. Комплекснозначные и гиперкомплексные системы в задачах обработки многомерных сигналов/ Под ред. Я.А. Фурмана. – М.: Физматлит, 2004.

Распознавание речи и диктора в системе мультимедийной идентификации личности

В.Я. Чучупал, К.А. Маковкин, Д.В. Ковков, А.В. Чичагов
(Москва)

Основная цель работы состояла в создании и исследовании свойств модуля распознавания речи и диктора для мультимедийной системы идентификации личности, которая оперирует в реальной акустико-фоновой обстановке.

Структура системы распознавания

Структура системы представлена на Рис 1.

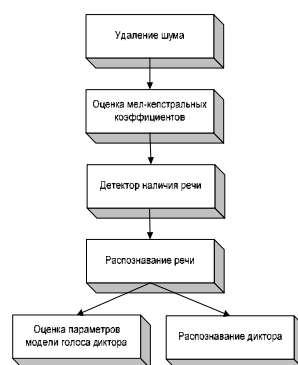


Рис. 1. Структура системы распознавания.

Модуль удаления шума основан на Винеровской фильтрации и соответствует алгоритмам европейского стандарта ES 202 050 [1].

Детектор речи выполняет декодирование последовательности векторов-параметров сигнала в последовательность двух состояний : речи и пауз.

Блок распознавания речи основан на применении аппарата скрытых марковских моделей и процедуры Витерби. Алфавит акустических моделей включает в себя 1500 моделей аллофонов, найденных путем построения бинарного решающего дерева на речевом корпусе данных TeCoRus [2].

Модель голоса диктора в системе - это множество произносительных

шаблонов для каждого слова словаря. Каждый шаблон, в свою очередь, это последовательность усредненных параметров речевого сигнала на участке, соответствующем состоянию марковской модели.

Модуль распознавания дикторов выполняет оценку меры сходства между шаблоном наблюдаемого слова и шаблоном, зарегистрированным в базе данных. Решение об идентичности принимается на основе величины меры сходства.

Экспериментальные результаты

Система распознавания дикторов была обучена и протестирована на корпусе данных FaVoR[3] (Face+Voice Recognition), который содержал более 1000 дикторов. Сессия включала в себя произнесение всех служебных слов словаря и цифр, а также произнесения своего и чужого (т.е. принадлежащего другому диктору) персональных номеров - ПИНов. Записи сделаны на удаленном микрофоне, в реальных акустико-фоновых условиях, среднее значение отношения сигнал-шум +15дБ, присутствует значительное количество нестационарных шумов, неречевых акустических событий, включений несловарных слов и т.п.

На Рис 2 представлена точность распознавания речи - отдельно для каждого слова словаря и для ПИНов. Ось Y соответствует проценту правильного распознавания, ось X соответствует длине списка лучших гипотез.




Рис. 2. Пословная точность и точность распознавая последовательностей слов (ПИНов).

Поскольку значительное число сессий содержало шумы и помехи, интересно проследить распределение ошибок по сессиям. Рис 3 изображает такое распределение (для первой лучшей гипотезы). Очевидно, что относительно малое число - примерно 15% всех сессий, приносит более 50% ошибок.




Рис. 3. Распределение числа ошибок по сессиям.

Точность распознавания дикторов оценивалась в терминах рабочей характеристики, представленной на рисунке 4. Ось X соответствует числу

пропусков (опознавания чужого диктора как своего), а ось Y соответствует числу ошибочных отказов в пропуске (опознавание своего как чужого).




Рис. 4. Операционная характеристика точности распознавания дикторов

Равная ошибка составляет 0.075. Полученные результаты распознавания по голосу являются вполне приемлемыми при создании мультимедийной системы распознавания личности, когда они комбинируются с результатами распознавания по лицу человека.

Благодарности

Авторы благодарны за помощь к.т.н. А. Мурынину (ВЦ РАН), В.Лобанцову (DANCOM), а также сотрудникам группы распознавания лиц центра Самсунг в Москве.

Работа выполнена при поддержке гранта РФФИ 04-01-00588.

Литература

1. European Standard Telecommunication Institute: ESTI Standard ES 202 050, www.esti.org,
2. Chuchupal V., Makovkin K., Gorokhovskiy K., Chichagov A. "A Study of the Acoustic Model Choice for Russian Speech Recognition" Proc of Int. Workshop "Speech and Computer", 2002, 53-56
3. DANCOM. www.dancom.ru

Вычисление сечения рождения нейтральных мезонов из сложного распределения массового спектра

А.А. Шумаков
(Протвино)

Задача была поставлена лабораторией ПФ ИФВЭ г.Протвино и заключалась в определении числа частиц, находящихся в определенном кинематическом интервале, полученного в результате эксперимента ПРОЗА-2. Распределение представляет собой сумму сигналов, полученного от реальных π^0 мезонов и фона. Сигнал от π^0 мезонов представляет собой распределение Гаусса с неизвестными параметрами.

Анализ возможных методов получения аналитического описания

показал, что наиболее полно поставленным условиям отвечает метод, основанный на аппроксимации данных отрезками ортогональных рядов с использованием классических ортогональных полиномов и функций непрерывного и дискретного аргументов.

Теория классических ортогональных базисов есть обобщение теории рядов Фурье на алгебраические полиномы. Их отличительная особенность состоит, главным образом, в том, что в большинстве формул, задающих конкретные базисы, имеются параметры, изменение которых может заметно менять свойства ортогональных полиномов и весовых функций, образующих конкретный ортогональный базис. Последнее обстоятельство особенно важно в задачах оптимальной аналитической аппроксимации, когда заданная точность должна быть обеспечена наиболее коротким отрезком ортогонального ряда.

В решении задачи использовался обобщенный спектрально-аналитический метод определения функций, описывающих сигнал от π^0 мезонов и фонового сигнала, представляемых наборами дискретных значений.

Аналитически описанные сигналы известны по всем параметрам и вычисление определенных интегралов реализовано.

Литература

1. Обобщенный спектрально-аналитический метод обработки информационных массивов. Задачи анализа изображений и распознавания образов. Ф.Ф.Дедус, С.А.Махортых, М.Н.Устинин, А.Ф.Дедус, Москва «Машиностроение» 1999г.

ОГЛАВЛЕНИЕ

I. Математическая теория распознавания.....4

<i>Айдарханов М.Б., Амиргалиев Е.Н.</i> Сложность алгоритмов решения задачи синтеза групповых классификации	4
<i>Амелькин С.А., Хачумов В.М.</i> Обобщенное расстояние евклида-махаланобиса и его применение в задачах распознавания образов.....	7
<i>Анциперов В.Е.</i> Метод коротких корреляционных функций в задачах структурирования сигналов сложной природы	10
<i>Апраушева Н.Н., Де Ванса Викраматне В.К., Сорокин С.В.</i> Использование метода статистических испытаний в определении мод гауссовой смеси.....	13
<i>Аслаян Л.А., Минго Л.Ф., Кастелянос Х.Б., Рязанов В.В., Челноков Ф.Б.</i> Нейросетевые алгоритмы распознавания с логической коррекцией.....	16
<i>Бабкин В.Ф., Ланге М.М.</i> О теоретико-информационной эффективности метода блоковых измерений	19
<i>Бабушкина Е.В., Чичагов В.В.</i> Интервальное оценивание риска процедуры групповой классификации с использованием несмещенных оценок.....	22
<i>Барина О.В.</i> Об одном методе прогнозирования временных рядов с несимметричным функционалом потерь	25
<i>Бериков В.Б., Лбов Г.С.</i> О прогнозирующей способности методов распознавания	29
<i>Бесполитов О.В.</i> Кодирование цифровых изображений с помощью дискретных ортогональных преобразований с «хаотическими» базисными функциями	32
<i>Бирюков А.С., Рязанов В.В.</i> О построении коллективных решений при решении задач кластерного анализа.....	34
<i>Бродская Ю.А.</i> Формирование тестов с минимальными затратами ресурсов и времени на частотных таблицах	37

<i>Брусенцов Н.П., Владимирова Ю.С.</i> Троичная компьютеризация логики	40
<i>Вайнцвайг М.Н., Полякова М.П.</i> Архитектура и функции модели организации поведения	42
<i>Васильев О.М.</i> Корректные алгоритмы в алгебраическом расширении одной П-модели алгоритмов классификации	45
<i>Ветров Д.П., Кропотов Д.А.</i> Об использовании методов Boosting в задачах генерации знаний	48
<i>Ветров Д.П., Кропотов Д.А., Пташко Н.О.</i> Использование принципа наибольшего основания для автоматического выбора ядерной функции	51
<i>Ветров Д.П., Кропотов Д.А., Пташко Н.О.</i> О связи Байесовской регуляризации с устойчивостью алгоритмов распознавания	54
<i>Ветров Д.П., Кропотов Д.А., Толстов И.В.</i> Применение принципа минимальной длины описания для обрезания бинарных решающих деревьев	57
<i>Викентьев А.А.</i> Расстояние на высказываниях экспертов и мера опровержимости (информативности) высказываний с помощью моделей некоторых теорий	60
<i>Виноградов А.П., Voracek J., Журавлев Ю.И.</i> Мультишкалы для приближенных симметрий в плотных упаковках кластеров	63
<i>Гимади Э.Х., Кельманов А.В., Кельманова М.А., Хамидуллин С.А.</i> Приближенный алгоритм для апостериорного обнаружения в числовой последовательности квазипериодически повторяющегося фрагмента при заданном числе повторов	66
<i>Глаз А.Б., Тимухин А.А.</i> Восстановление 3D поверхности лиц на базе исходных 2D изображений	69
<i>Горелов Ю.И.</i> О разрешимости и регулярности задач распознавания со специальной структурой F-расширений моделей алгоритмических операторов	72
<i>Гранкин М.В., Гулов С.И.</i> Определение областей компетентности алгоритмов синтеза управляющих систем	75

<i>Гуров С.И.</i> Оценки числа монотонных булевых функций с данным числом нижних единиц	78
<i>Двоенко С.Д.</i> Обучение распознаванию с учетом априорной упорядоченности объектов.....	81
<i>Дедус Ф.Ф.</i> Достижения и перспективы развития обобщенного спектрально-аналитического метода в решении сложных информационных задач.....	84
<i>Дергузов А.В., Махортых С.А.</i> Резонансно – импедансный метод диагностики одномерных акустических систем	86
<i>Джунгурова О.С.</i> Реализация некоторых операций над отрезками ортогональных рядов полиномов Кравчука.....	89
<i>Донской В.И.</i> Оценивание VCD семейств алгоритмов на основе колмогоровской сложности	92
<i>Дьяконов А.Г.</i> Об одном подходе к решению задач из области ВСІ.....	95
<i>Дюкова Е.В., Инякин А.С.</i> О сложности нахождения элементарных классификаторов в логических процедурах распознавания и классификации.....	97
<i>Емельянов Г.М., Попов С.А.</i> Обратная оптимизация в многокритериальных задачах.....	101
<i>Ефимов А.Н.</i> Размерностный подход к анализу метрических конфигураций.....	104
<i>Загоруйко Н.Г., Кутненко О.А., Борисова И.А.</i> Выбор информативного подпространства признаков (Алгоритм GRAD).....	106
<i>Захаров А.М., Кумсков М.И., Пономарева Л.А.</i> Эволюционный алгоритм построения моделей «структура-свойство» для молекулярных поверхностей с использованием аппарата нечеткой логики	109
<i>Зубюк А.В.</i> Эмпирическое восстановление возможности.....	112
<i>Иванова Е.А., Жданов С.А., Матросов В.Л.</i> Оценка индекса системы событий.....	115

<i>Казакова Т.В., Стрижов В.В., Шакин В.В.</i> Построение устойчивых интегральных индикаторов.....	116
<i>Каневский Д.Ю.</i> Генетические алгоритмы синтеза алгоритмических композиций в задачах распознавания	119
<i>Катериночкина Н.Н.</i> Методы выделения оптимальной совместной подсистемы системы линейных неравенств.....	122
<i>Кельманов А.В.</i> Апостериорный подход к решению типовых задач анализа и распознавания числовых квазипериодических последовательностей: обзор результатов.....	125
<i>Кельманов А.В., Хамидуллин С.А.</i> Максимально правдоподобное апостериорное обнаружение и идентификация фрагментов числовой последовательности по их обрывкам.....	128
<i>Кобылкин К.С.</i> О построении комитета двумерной системы неоднородных линейных неравенств.....	131
<i>Кольцов Д.А., Сердобольская М.Л.</i> Об одной нетрадиционной задаче проверки сложных гипотез.....	134
<i>Копылов А.В.</i> Итерационные методы парно-сепарабельной оптимизации на основе древовидного динамического программирования в задачах анализа многомерных данных.....	137
<i>Копылов А.В., Красоткина О.А., Моттль В.В.</i> Критерии и алгоритмы оценивания нестационарной регрессии в анализе временных рядов	140
<i>Котельников И.В.</i> Определение типа фазовых траекторий динамических систем на основе оптимальных тупиковых нечетких тестов и синдромов	144
<i>Кувшинов Б.М.</i> Адаптивная модель распознавания образов для задач оценивания и прогнозирования в условиях неопределенности.....	147
<i>Кузнецов С.О., Самохин М.В.</i> Машинное обучение на данных, представленных помеченными графами	150
<i>Ланге М.М., Ганебных С.Н.</i> Многоуровневая структура данных и быстрый поиск на основе последовательных приближений.....	153

<i>Лапко В.А.</i> Синтез и анализ непараметрических систем классификации множеств случайных величин.....	156
<i>Лапко А.В., Лапко В.А.</i> Непараметрические и гибридные системы классификации разнотипных данных.....	159
<i>Лбов Г.С., Бериков В.Б.</i> Прогнозирование экстремальных событий в классе логических решающих функций.....	162
<i>Майсурадзе А.И.</i> Об эффективном поиске оптимального группового слагаемого для набора метрических конфигураций.....	166
<i>Матросов В.Л., Угольников Б.З.</i> Об одной системе экспертов, меняющейся во времени	169
<i>Морозов А.А., Морозов В.А., Обухов Ю.В., Строганова Т.А., Цетлин М.М.</i> Разработка логико-вероятностного метода описания и поиска закономерностей в пространственно-временных сигналах на основе логики первого порядка и медианного анализа	170
<i>Мустафин С.А.</i> О методике распознавания плоских кривых.....	173
<i>Неделько В.М.</i> Емкостная характеристика выбора подпространства признаков.....	174
<i>Неймарк Ю.И., Котельников И.В., Теклина Л.Г.</i> Исследование структуры фазового пространства динамической системы как задача распознавания образов	177
<i>Неймарк Ю.И., Теклина Л.Г.</i> Авторегрессионный анализ фазовых траекторий динамических систем..	180
<i>Нефедов А.Г.</i> Параметризация рукописных слов и траектории движения пера при анализе сканированных рукописных документов	183
<i>Панкратов А.Н.</i> Об информационной технологии спектрального анализа высокого разрешения	186
<i>Посыпкин М.А., Сигал И.Х.</i> Применение алгоритмов параллельных вычислений для решения задач дискретной оптимизации и распознавания	187
<i>Пташко Г.О., Стрижов В.В., Шакин В.В.</i> Выбор функции расстояния при сравнении фазовых траекторий	190

<i>Пытьев Ю.П.</i> Вероятность и возможность. Эмпирическая интерпретация и оценивание	192
<i>Романов Л.Ю.</i> О синтезе нелинейных разделителей с использованием спрямляющих пространств	195
<i>Романов М.Ю.</i> О максимальных гранях булевых функций с малым числом нулей.....	199
<i>Сенько О.В., Кузнецова А.В.</i> Алгоритм распознавания, основанный на голосовании по наборам закономерностей различных типов	200
<i>Соболев К.С., Мондрус О.В., Шишаков В.В.</i> О теоретико-вероятностных и теоретико-возможностных алгоритмах редукции многомерных данных: сравнительный анализ	203
<i>Стрижов В.В.</i> Поиск модели оптимальной сложности в задачах нелинейной регрессии.....	206
<i>Ступина Т.А.</i> Оценка смещения функционала качества в задаче прогнозирования многомерной разнотипной переменной	209
<i>Таратынова Н.Ю.</i> Задача линейной оптимизации с прецедентной начальной информацией	213
<i>Тетуев Р.К.</i> Вычисление некоторых геометрических характеристик плоских кривых на основе спектральных методов	215
<i>Тихомиров М.Г.</i> Об одном подходе к синтезу «простых» процедур распознавания	218
<i>Фаломкина О.В., Матвеева Т.В., Пытьев Ю.П.</i> Неопределенная стохастическая модель.....	219
<i>Фаломкина О.В., Пытьев Ю.П.</i> О критериях оптимальности для неопределенных нечетких моделей	222
<i>Хачай М.Ю.</i> О вычислительной сложности задачи о минимальном аффинном разделяющем комитете	226
<i>Чернов В.М.</i> Прикладные аспекты теории канонических систем счисления в полях алгебраических чисел.....	229

<i>Чичева М.А., Алиев М.В.</i> Гиперкомплексное дискретное преобразование Фурье произвольной размерности: параллельный подход.....	232
<i>Чукалина М.В., Функе Х., Шабельникова С.Л.</i> Математические аспекты проблемы идентификации центров рассеяния на базе обработки спектров EXAFS: выбор материнского вэйвлета.....	235
<i>Шибзухов З.М.</i> Последовательности расширений конечных множеств некорректных распознающих алгоритмов.....	239
<i>Юдин В.Н.</i> Мера близости в системе вывода на основе прецедентов	241
<i>Янковская А.Е.</i> Ускоренный алгоритм удаления поглощающих строк в булевой матрице и его применение в задачах распознавания образов	245

II. Прикладные задачи и системы распознавания.....248

<i>Амирғалиев Е.Н.</i> Объектно-ориентированный анализ и проектирование многоуровневой системы классификации	248
<i>Андреев С.А., Борисов С.А.</i> Определение тональности музыкальных произведений.....	251
<i>Аппанов А.Ю., Барабаненков Ю.Н., Обухов Ю.В.</i> Итерационный способ последовательного перехода от метода Монте-Карло к диффузионному приближению в оптическом изображении биологических сред.....	253
<i>Баврина А.Ю., Глумов Н.И., Сергеев В.В., Тимбай Е.И.</i> Метод иерархической компрессии индексных изображений с разбиением на цветные плоскости	256
<i>Барина О.В., Вальков А.С., Воронцов К.В., Громов С.А., Ефимов А.Н., Чехович Ю.В.</i> Система прогнозирования потребительского спроса Goods4Cast.....	258
<i>Берестнева О.Г., Добрянская Р.Г., Муратова Е.А.</i> Применение технологии Data Mining для прогнозирования исхода родов	260
<i>Богатов Н.М., Гук В.Ф.</i> Цифровой анализ электрокардиограмм	263

<i>Богданкевич Н.М., Чуличков А.И.</i> Моделирование и анализ изображений белковых комплексов тилакоидной мембраны	265
<i>Боснякова Д.Ю., Босняков М.С., Гуляев Ю.В., Обухов Ю.В.</i> Метод глубинной пассивной термографии тела человека	268
<i>Ботуз С.П., Калыкин С.С., Лисицын И.М., Моисеева В.С., Четверов С.Ю.</i> Методы и модели аутентификации/идентификации систем автоматического сканирования	271
<i>Будько М.Б.</i> Реализация метода ускоренного выполнения кратковременного анализа	273
<i>Васильев А.В.</i> Определение значимости тематических запросов к информационно- поисковой системе на основе модели графа связей запросов	276
<i>Васин Ю.Г., Лебедев Л.И.</i> Распознавание линейных объектов с периодической формой представления	279
<i>Галицкий Е.Б., Моттль В.В., Татарчук А.И.</i> Обучение распознаванию образов в анализе данных опросов населения	282
<i>Гашиников М.В., Глумов Н.И.</i> Предварительная фильтрация при иерархической компрессии изображений	286
<i>Голов Н.И.</i> Отдельные алгоритмы, применяемые в реализации морфологического метода сравнения радужных оболочек глаз	289
<i>Грабарник П.Я., Смирнов В.Э.</i> Моделирование случайных мозаик для задач обработки данных лесной таксации	292
<i>Де Ванса Викрамаратне В.К.</i> Метод анализа изображений для обнаружения объектов на статическом фоне	294
<i>Демьянов Е.А., Дюкова Е.В., Инякин А.С., Песков Н.В.</i> Библиотека дискретных (логических) алгоритмов распознавания и классификации для параллельных компьютеров	297
<i>Докукин А.А.</i> О сложности поиска оптимального в некотором смысле ABO	299

<i>Доленко С.А., Орлов Ю.В., Персианцев И.Г., Шугай Ю.С.</i> Разработка нейросетевых алгоритмов анализа многомерных временных рядов и их применение при исследовании солнечно-земных связей.....	302
<i>Домахин М.А., Местецкий Л.М., Мехедов И.С., Петрова Л.Г.</i> Восстановление полутонных изображений по изолиниям яркости.....	305
<i>Ермаков А.С., Левянт В.Б., Моттль В.В.</i> Прогнозирование разуплотненных зон в кристаллическом фундаменте на основе распознавания аномалий рассеянной компоненты сейсмического поля	308
<i>Ефимов С.А.</i> Метод обработки вибросейсмических сигналов для формирования сейсмограмм при использовании монохроматических зондирующих источников	311
<i>Ефимов С.А.</i> Особенности обработки вибросейсмических данных при формировании виброграмм в частотном пространстве.....	315
<i>Жарких А.А., Юрко А.С.</i> Анализ и синтез контурных изображений на основе вейвлет-преобразования Хаара.....	318
<i>Животников Г.С., Пытьев Ю.П., Фаломкин И.И.</i> Итеративный морфологический алгоритм локализации в реальном времени неизвестного объекта на изображении.....	322
<i>Жукова К.В., Рейер И.А.</i> Биометрическая идентификация по линии профиля на основе гранично-скелетного представления.....	325
<i>Журавлев Ю.И., Рудаков К.В., Инякин А.С., Кирсанов А.А., Лисица А.В., Никитов Г.В., Песков Н.В., Романов М.Ю., Чехович Ю.В., Яминов Р.И.</i> Система распознавания интеллектуальных заимствований «Антиплагиат».....	329
<i>Захаров А.М., Свитанько И.В., Григорьева С.С., Чичуа В.Т.</i> Поиск особых точек на молекулярных поверхностях с использованием нечеткого кластер-анализа.	333
<i>Захарченко А.А.</i> Морфологические методы анализа многофокусных изображений	335
<i>Квашнин К.М., Кумсков М.И.</i> Особенности архитектуры системы распознавания объектных моделей OMRESYS (Object Model Recognition SYStem).....	338

<i>Квашин К.М., Кумсков М.И.</i> Особенности архитектуры системы распознавания объектных моделей для выполнения на многопроцессорных вычислительных комплексах ...	341
<i>Колчев А.А., Щирый А.О.</i> Удаление зашумленного фона с изображения ионограммы наклонного зондирования ионосферы	344
<i>Котик С.В., Майсурадзе А.И., Местецкий Л.М.</i> Сжатие полутоновых изображений рукописных документов на основе кодирования по изолиниям яркости.....	346
<i>Кочедыков Д.А., Ивахненко А.А., Воронцов К.В.</i> Система кредитного скоринга на основе логических алгоритмов классификации	349
<i>Кругов А.Е.</i> Об одном алгоритме динамического обучения принятию решений в дискретных временных рядах	353
<i>Кузнецова А.В., Мамаев В.Б., Сенько О.В.</i> Логико-статистическое прогнозирование биологического возраста по данным биоактивных точек.....	356
<i>Куликова Л.И., Махортых С.А.</i> Спектральное разложение данных магнитной энцефалографии и вывод аналитических соотношений между коэффициентами разложения при типовых операциях с сигналами.....	360
<i>Курганский Д.А.</i> Анализ ритма и определение темпа музыкальных произведений	362
<i>Лучишева Т.И.</i> Построение математической модели организации медицинской помощи пострадавшим при ЧС	364
<i>Любецкий В.А.</i> Математические модели эволюции и регуляции экспрессии генов	366
<i>Максаков А.В.</i> Масштабируемые алгоритмы классификации текстов.....	368
<i>Манило Л.А.</i> Линейный дискриминант Фишера в задачах распознавания биосигналов по частотным свойствам	371
<i>Масалович А.А.</i> Кластеризация изображений графем на основе непрерывного гранично-скелетного представления.....	374

<i>Матросов В.Л., Кулясов С.М.</i> Метод выделения границ объектов и слаборазличимых объектов на изображении, как предварительный этап решения задачи распознавания	378
<i>Мирошниченко С.Ю., Дегтярев С.В.</i> Биноккулярный оптико-электронный диагностический комплекс	380
<i>Михайлов Д.В., Емельянов Г.М.</i> Применение семантических полей словаря РОСС в задаче построения Модели Управления предикатного слова	382
<i>Михеев П.Н.</i> Использование методов компьютерной графики для генерации расчетных сеток в численных моделях океанов и морей ..	385
<i>Немирко А.П., Луговая Т.С.</i> Биометрическая идентификация личности по электрокардиограмме	387
<i>Никитов Г.В.</i> О проблеме формализации понятия «плагиат» как о проблеме распознавания	390
<i>Никифорова Т.В.</i> Техническая дефектоскопия на основе методов стохастической геометрии	392
<i>Ольшевец М.М.</i> Анализ изображений и элементы цифровой диагностики в системе цифровой беспленочной рентгенографии	395
<i>Панков А.Р., Семенихин К.В.</i> Проблемы минимаксного оценивания в линейных неопределенно-стохастических системах	397
<i>Пестунов И.А., Синявский Ю.Н.</i> Быстрый непараметрический алгоритм кластеризации многоспектральных изображений	400
<i>Постников В.В., Марченко А.Е.</i> CFML: язык описания многостраничных структурированных документов для их идентификации и распознавания	404
<i>Пржиялковский В.В.</i> Объекты с собственной структурой в СУБД Oracle и в стандартном SQL	407
<i>Пролубников А.В.</i> Распознавание изображений при помощи алгоритма поиска оптимального вложения графа	410

<i>Пролубников А.В., Ржаницын Г.С., Файзуллин Р.Т.</i> Защита передачи видеоданных на основе применения алгоритмов проверки изоморфизма графов.....	413
<i>Пытьев Ю.П., Чуличков А.И.</i> Морфологический анализ изображений: итоги и перспективы.....	416
<i>Роженцов А.А.</i> Потенциальная эффективность идентификации заданного фрагмента береговой линии	419
<i>Роженцов А.А., Хафизов Р.Г., Добрынская Н.А.</i> Потенциальная эффективность распознавания объектов по их форме, задаваемой непрерывным контуром.....	420
<i>Романов М.Ю., Ументаев С.А., Кругов А.Е., Воронцов К.В.</i> Алгоритмы динамического обучения принятию решений в задаче формирования инвестиционного портфеля	423
<i>Саакян Р.Р., Шпехт И.А., Климов В.А., Верес И.Н.</i> Формирование классификационно-ориентирующих баз экспериментальных данных с применением расширенного метода линейных направлений - согласующих функций при изучении функционирования ткацкого станка.....	426
<i>Саакян Р.Р., Шпехт И.А., Руденко Е.Н.</i> Реализация расширенного метода линейных направлений-согласующих функций при прогнозировании поведения керамики под воздействием радиоактивного облучения.....	429
<i>Сахаров А.А.</i> Реализация одного алгоритма понижения значности исходной информации в системах с параллельными вычислениями	432
<i>Свенч А.А., Файзуллин Р.Т.</i> Представление геометрического объекта списком метрических характеристик	434
<i>Семенов А.Б., Чертоусов Д.А.</i> Метод биометрической идентификации личности по форме ладони	438
<i>Сергунин С.Ю., Кумсков М.И.</i> Свойства модели объекта в системе распознавания с активным сенсором	441
<i>Сергунин С.Ю., Кумсков М.И.</i> Диалоговое обучение системы распознавания сцен с активным сенсором	444

<i>Сергунин С., Миловидов А., Лозинский В., Кравченко Д.</i> Примеры построения алфавитов описания окна активного сенсора в РОАС системе.....	447
<i>Сидорова В.С.</i> Меры оценки качества классификации многоспектральных изображений	450
<i>Синицын И.Н., Корепанов Э.Р., Ильясов Д.Ф., Агафонов Е.С.</i> Опыт разработки информационных технологий стохастической обработки и аудита электронных таблиц.....	453
<i>Сулимова В.В., Моттль В.В., Середин О.С., Красоткина О.В.</i> Комбинирование потенциальных функций при верификации личности по динамике подписи.....	456
<i>Труфанов М.И., Титов В.С.</i> Способы автоматического повышения точности формирования изображения бинокулярной системы технического зрения.....	460
<i>Фаломкин И.И. Пытьев Ю.П.</i> Адаптивный морфологический алгоритм локализации объектов на изображении	463
<i>Федотов Н.Г., Моисеев А.В., Шульга Л.А.</i> Грассе-преобразование в предварительной обработке изображений.....	466
<i>Федотов Н.Г., Моисеев А.В., Шульга Л.А.</i> Двойственное грассе-преобразование в предварительной обработке изображений.....	469
<i>Федотов Н.Г., Шульга Л.А., Моисеев А.В., Кольчугин А.С.</i> Анализ свойств признаков распознавания, основанных на стохастической геометрии, при различных вариантах сканирования изображений.....	472
<i>Федотов Н.Г., Шульга Л.А., Моисеев А.В., Кольчугин А.С.</i> Сканирование со случайными параметрами как источник повышения быстродействия систем распознавания, основанного на методах стохастической геометрии.....	475
<i>Фурман Я.А., Хафизов Р.Г.</i> Формирование меры схожести кватернионных сигналов при распознавании 3D	479
<i>Чучупал В.Я., Маковкин К.А., Ковков Д.В., Чичагов А.В.</i> Распознавание речи и диктора в системе мультимедийной идентификации личности	481
<i>Шумаков А.А.</i> Вычисление сечения рождения нейтральных мезонов из сложного распределения массового спектра	484

Научное издание

Сборник докладов
XII Всероссийской конференции

**МАТЕМАТИЧЕСКИЕ МЕТОДЫ
РАСПОЗНАВАНИЯ ОБРАЗОВ**

Напечатано с готового оригинал-макета

Издательство ООО «МАКС Пресс»
Лицензия ИД N 00510 от 01.12.99 г.
Подписано к печати 27.10.2005 г.
Формат 60x90/16. Усл.печ.л. 31,25. Тираж 500 экз. Заказ 706.

119992, ГСП-2, Москва, Ленинские горы, МГУ им. М.В. Ломоносова,
2-й учебный корпус, 627 к.
Тел. 939-3890, 939-3891. Тел./Факс 939-3891.