

Об оптимальном выборе закономерностей, составляющих плавно меняющуюся закономерность

Филипенков Н. В.

filipenkov@mail.ru

Москва, Вычислительный Центр РАН

В работе [2] был предложен подход к поиску плавно меняющихся закономерностей в пучках временных рядов. Идея подхода состоит в разбиении исходного пучка временных рядов на отрезки, на каждом из которых применяется алгоритм поиска постоянных закономерностей. Наиболее близкие (в смысле определённой в работе [2] меры сходства) закономерности, полученные на различных отрезках, «склеиваются» в плавно меняющуюся закономерность. Однако в упомянутой работе достаточно слабо был освещён вопрос выбора постоянных закономерностей при построении плавно меняющейся закономерности. Настоящая работа ставит своей целью заполнить этот пробел.

Пучком временных рядов \mathfrak{S} называется совокупность взаимосвязанных временных рядов S_i , $i = 1, \dots, N$. Каждый ряд S_i представляет собой последовательность чисел конечнозначной логики E_{k_i} . Значение ряда S_i в момент времени $t \in \{1, \dots, T\}$ обозначим $a(i, t)$. *Маской* ω на прямоугольнике $N \times \Delta$ называется булева матрица размерности $N \times \Delta$ (здесь параметр Δ определяет максимальный отступ по времени). Число единиц в маске ω называется *мощностью* маски и обозначается $\|\omega\|$. Элемент маски, находящийся в i -ой строке и j -ом столбце обозначается $\omega(i, j)$. *Закономерностью* R (постоянной) называется набор (p, ω, f) , где число $p \in \{1, \dots, N\}$ указывает на целевой ряд (то есть ряд, значения которого определяются закономерностью R); маска ω указывает на значения рядов, являющиеся аргументами функции f ; частично-определённая функция f задаёт зависимость значений целевого ряда от переменных, на которые указывает маска ω .

$$f: E_{k_{i_1}} \times \dots \times E_{k_{i_{\|\omega\|}}} \rightarrow E_{k_p} \cup \{\lambda\},$$

где $\omega(i_1, j_1), \dots, \omega(i_{\|\omega\|}, j_{\|\omega\|})$ — единичные элементы матрицы ω , p — номер целевого ряда, символ λ обозначает, что функция f не определена на соответствующем наборе значений переменных.

Отрезком \mathfrak{S}_1 с *началом* $t_b \in \{0, \dots, T\}$ и *концом* $t_e \in \{0, \dots, T\}$, ($t_b < t_e$) на пучке временных рядов \mathfrak{S} (обозначается $\mathfrak{S}_1 \subset \mathfrak{S}$) назовём матрицу $N \times \theta$, составленную из последовательных столбцов матрицы \mathfrak{S} , первым из которых является столбец с номером t_b , последним — столбец с номером t_e , где $\theta = t_e - t_b + 1$ называется *длиной* отрезка \mathfrak{S}_1 .

Определим следующие показатели качества постоянных закономерностей. Их названия совпадают с принятыми в нечёткой логике [1] показателями качества правил, так как несут сходный смысл. *Репрезентативностью* $\text{rep}(R)$ ($0 \leq \text{rep}(R) \leq 1$) закономерности $R = (p, \omega, f)$ назовём следующую величину:

$$\text{rep}(R) = \frac{|D(\omega)|}{k_{i_1} \cdots k_{i_{\|\omega\|}}},$$

где $|D(\omega)|$ — число наборов из $E_{k_{i_1}} \times \dots \times E_{k_{i_{\|\omega\|}}}$, на которых значение функции f отлично от λ , а $\omega(i_1, j_1), \dots, \omega(i_{\|\omega\|}, j_{\|\omega\|})$ — единичные элементы матрицы ω .

Локальной эффективностью $\text{eff}_\varepsilon(R, t)$ ($0 \leq \text{eff}(R) \leq 1$) закономерности R в точке t назовём следующую величину:

$$\text{eff}_\varepsilon(R, t) = 1 - \frac{1}{2\varepsilon + 1} \sum_{i=-\varepsilon}^{\varepsilon} \left(\frac{\hat{a}(t+i) - a(p, t+i)}{k_p} \right)^2,$$

где $\hat{a}(t)$ — прогноз закономерности R для значения $a(p, t)$ пучка временных рядов.

Плавно меняющейся закономерностью $\tilde{R} \in \mathfrak{R}^{T-\Delta}$ на пучке временных рядов \mathfrak{S} называется последовательность постоянных закономерностей $R_{\Delta+1}, \dots, R_T$ такая, что элементы $a(p, \Delta+1), \dots, a(p, T)$ пучка временных рядов \mathfrak{S} прогнозируются соответственно постоянными закономерностями $R_{\Delta+1}, \dots, R_T$. При этом $R_{\Delta+1}, \dots, R_T$ могут представлять собой одни и те же закономерности.

Определим три основных показателя качества плавно меняющейся закономерности в точке пучка временных рядов.

Локальной репрезентативностью $\widetilde{\text{rep}}_\varepsilon(\tilde{R}, t)$ и *локальной эффективностью* $\widetilde{\text{eff}}_\varepsilon(\tilde{R}, t)$ плавно меняющейся закономерности \tilde{R} в ε -окрестности точки t пучка временных рядов \mathfrak{S} называются следующие величины:

$$\widetilde{\text{rep}}(\tilde{R}, t) = \text{rep}(R_t), \quad \widetilde{\text{eff}}_\varepsilon(\tilde{R}, t) = \text{eff}_\varepsilon(R_t, t).$$

Третьим показателем качества плавно меняющейся закономерности в точке t пучка временных рядов \mathfrak{S} является значение $\rho(R_t, R_{t+1})$ — меры сходства закономерностей R_t и R_{t+1} . Для точки T данный показатель принимается равным нулю. Определение меры сходства закономерностей подробно рассмотрено в работе [2]. Заметим, что значение меры сходства закономерностей несёт смысл штрафа за смену закономерностей, и этот штраф тем больше, чем больше различие между закономерностями.

На основании приведённых выше локальных показателей качества плавно меняющейся закономерности \tilde{R} определяются показатели качества \tilde{R} на всём пучке временных рядов. *Средней репрезентативностью* $\tilde{\text{rep}}(\tilde{R})$ и *средней эффективностью* $\tilde{\text{eff}}(\tilde{R})$ закономерности \tilde{R} называются следующие показатели:

$$\tilde{\text{rep}}(\tilde{R}) = \frac{\sum_{i=\Delta+1}^T \tilde{\text{rep}}(\tilde{R}, t)}{T - \Delta}, \quad \tilde{\text{eff}}(\tilde{R}) = \frac{\sum_{i=\Delta+1}^T \tilde{\text{eff}}_0(\tilde{R}, t)}{T - \Delta}.$$

Здесь $\tilde{\text{eff}}_0(\tilde{R}, t)$ — локальная эффективность $\tilde{\text{eff}}_\varepsilon(\tilde{R}, t)$ при $\varepsilon = 0$.

Длиной $l(\tilde{R})$ изменяющейся закономерности \tilde{R} называется следующий показатель качества плавно меняющейся закономерности \tilde{R} :

$$l(\tilde{R}) = \sum_{t=\Delta+1}^{T-1} \rho(R_t, R_{t+1}).$$

Поиск наилучшей плавно меняющейся закономерности \tilde{R} сводится к задаче многокритериальной оптимизации:

$$\begin{cases} \tilde{\text{rep}}(\tilde{R}) \rightarrow \max_{\tilde{R} \in \mathfrak{R}^{T-\Delta}} ; \\ \tilde{\text{eff}}(\tilde{R}) \rightarrow \max_{\tilde{R} \in \mathfrak{R}^{T-\Delta}} ; \\ l(\tilde{R}) \rightarrow \min_{\tilde{R} \in \mathfrak{R}^{T-\Delta}} . \end{cases}$$

Здесь оптимизация происходит по всем возможным закономерностям \tilde{R} , т. е. по всем последовательностям постоянных закономерностей $R_{\Delta+1}, \dots, R_T$.

Литература

- [1] Барсегян А. А., Куприянов М. С., Степаненко В. В., Холод И. И. Методы и модели анализа данных: OLAP и Data Mining. — СПб.: БХВ-Петербург, 2004.
- [2] Филипенков Н. В. О задачах анализа пучков временных рядов с изменяющимися закономерностями // Искусственный интеллект — Донецк, 2006. — № 2. — С. 125–129.