

МЕТОДЫ СТАТИСТИЧЕСКОЙ КЛАССИФИКАЦИИ СТАЦИОНАРНЫХ ВРЕМЕННЫХ РЯДОВ

Микулич Г. В., Жук Е. Е.

Кафедра математического моделирования и анализа данных,

Белорусский государственный университет

Минск, Республика Беларусь

E-mail: aragornugua@gmail.com, zhukee@mail.ru

Рассматриваются различные подходы к проблеме статистической классификации стационарных в широком смысле временных рядов: классификация коэффициентов авторегрессии и ковариационных функций.

ВВЕДЕНИЕ

Задача статистической классификации является одной из основных прикладных задач математической статистики. При этом, данные, подлежащие классификации, во многих случаях находятся в формате временных рядов, например: биомедицинские измерения (электрокардиограмма, кровяное давление), данные о погоде, цены акций на бирже и др. В данной работе изучается частный случай стационарных временных рядов, поскольку исследование нестационарных временных рядов может быть сведено к исследованию стационарных [1]. Рассматривается два подхода к решению задачи, а также построены решающие правила для алгоритмов, например, дискриминантного или кластерного анализа.

I. МАТЕМАТИЧЕСКАЯ МОДЕЛЬ

Различие подходов заключается в разном выборе признаков для классификации: в первом случае это коэффициенты авторегрессии модели $AR(p)$, а во втором – ковариационные функции реализаций стационарных временных рядов. Обозначим подход через классификацию коэффициентов авторегрессии как первый, а через ковариационные функции – как второй. Опишем обе математические модели, принимая во внимание то, что разделение на классы неодинаково для разных подходов.

Пусть наблюдается случайная выборка $X^n = (X_1, \dots, X_n)$ объёма n из независимых в совокупности случайных векторов наблюдений, принадлежащих к $L \geq 2$ классам $\Omega_1, \dots, \Omega_L$. Наблюдение X_t принадлежит к классу со случайным ненаблюдаемым номером $d_t^0 \in S$, $S = \{1, \dots, L\}$, $t = \overline{1, n}$ и при фиксированном номере класса $d_t^0 = i$, $i \in S$ является:

1. Реализацией длительности T_t ($X_t = (x_{t1}, \dots, x_{tT_t})' \in R^{T_t}$, ' – символ транспонирования) временного ряда авторегрессии $x^i = \{x_l^i\}_{l=-\infty}^{+\infty}$ порядка $p \geq 1$ (модель $AR(p)$)

$$x_l^i + \theta_{i1}^0 x_{l-1}^i + \dots + \theta_{ip}^0 x_{l-p}^i = u_l^i, l \in Z, (1)$$

где $Z = \{0, \pm 1, \pm 2, \dots\}$, $\theta_i^0 \in R^p$ – вектор авторегрессии для i -го класса, а $\{u_l^i\}_{l=-\infty}^{+\infty}$ –

независимые в совокупности нормальные случайные величины с нулевым математическим ожиданием и одинаковой дисперсией σ^2 для всех классов Ω_i :

$$E \{u_l^i\} = 0, D \{u_l^i\} = \sigma^2, l \in Z, i \in S. (2)$$

2. Реализацией длительности T_t стационарного временного ряда с нулевым математическим ожиданием и ковариационной функцией $\sigma_i(h)$:

$$E \{x_{tj} | d_t^0 = i\} = 0, j = 1, 2, \dots$$

$$\sigma_i(h) = \sigma_i(-h) = E \{x_{tj}, x_{t, j+h} | d_t^0 = i\},$$

$$h = 0, 1, 2, \dots, i \in S. (3)$$

Наряду с вектором коэффициентов авторегрессии θ_i^0 для первого случая и ковариационными функциями $\{\sigma_i(\cdot)\}_{i \in S}$ для второго случая, классы Ω_i также характеризуется своей априорной вероятностью:

$$P \{d_t^0 = i\} = \pi_i^0 > 0, i \in S, \sum_{i=1}^L \pi_i^0 = 1. (4)$$

II. КЛАССИФИКАЦИЯ В ПРОСТРАНСТВЕ ОЦЕНОК КОЭФФИЦИЕНТОВ АВТОРЕГРЕССИИ

Используем модель (1),(2),(4). Преобразуем исходную выборку X^n в выборку $Y^n = (Y_1, \dots, Y_n)$, где $Y_t \in R^p$, $t = \overline{1, n}$ – МП-оценка для p -вектора коэффициентов авторегрессии $\theta_{d_t^0}^0 \in R^p$, построенная по наблюдению $X_t \in R^{T_t}$, являющемуся реализацией длительности T_t одного из временных рядов $AR(p)$ из (1).

Для построения МП-оценки Y_t воспользуемся тем фактом, что наблюдение $X_t \in R^{T_t}$ при фиксированном $d_t^0 = i$, $i \in S$ является нормальным T_t -вектором с нулевым математическим ожиданием $E \{X_t | d_t^0 = i\} = 0_{T_t}$, и плотностью распределения вероятностей

$$p(X_t; \theta_i^0, \sigma) = n_p(X_t^p | 0_p, R_p(\theta_i^0, \sigma)) \times \\ \times (2\pi)^{-\frac{T_t-p}{2}} \sigma^{-(T_t-p)} \times (5)$$

$$\times \exp\left(\frac{-1}{2\sigma^2} \sum_{l=p+1}^{T_t} (x_{tl} + \theta_{i1}^0 x_{t,l-1} + \dots + \theta_{ip}^0 x_{t,l-p})^2\right).$$

В формуле (5) $n_p(y|\mu, \Sigma)$ – плотность p -мерного нормального распределения, $X_t^p = (x_{t1}, \dots, x_{tp})^t \in R^p$, $R_p(\theta_i^0, \sigma) = E\{X_t^p(X_t^p)^t | d_t^0 = i\}$ – невырожденная [2] ковариационная матрица, элементами которой являются автоковариации $(\rho_{|k-l|}(\theta_i^0, \sigma))_{k,l=1}^p$, определяемые системой уравнений Юла – Уокера [3]:

$$\sum_{j=1}^p \theta_{ij}^0 \rho_j(\theta_i^0, \sigma) = \sigma^2;$$

$$\sum_{j=1}^p \theta_{ij}^0 \rho_{|k-j|}(\theta_i^0, \sigma) + \rho_k(\theta_i^0, \sigma) = 0, \quad k = 1, 2, \dots$$

Согласно методу максимального правдоподобия,

$$\{Y_t, \hat{\sigma}_t\} = \arg \max_{\{\theta, \sigma\}} \ln p(X_t; \theta, \sigma),$$

где $p(X_t; \theta, \sigma)$ – плотность из (5), записанная для $\bar{\theta}$, $\theta_i^0 := \theta$. Получаем следующее решающее правило:

$$\hat{d}_t = \arg \min_{i \in S} |Y_t - \hat{\theta}_i|, \quad t = \overline{1, n}.$$

Для решения задачи дискриминантного анализа по вектору истинной классификации строим оценки для "центров" классов (в случае кластерного анализа, например, с помощью алгоритма L -средних, вектор истинной классификации заменяется на оценки, полученные на соответствующем шаге алгоритма):

$$\hat{\theta}_i = \left(\sum_{t=1}^n \delta_{d_t, i} \right)^{-1} \sum_{t=1}^n \delta_{d_t, i} Y_t, \quad i \in S$$

III. КЛАССИФИКАЦИЯ В ПРОСТРАНСТВЕ КОВАРИАЦИОННЫХ ФУНКЦИЙ

Используем модель (3), (4). Введем обозначения:

$$\bar{\sigma}_i = (\sigma_i(0), \sigma_i(1), \dots, \sigma_i(N))^T \in R^{N+1} \quad (6)$$

вектор, образованный из первых $N + 1$ ковариаций (значений ковариационной функции, определяющих класс Ω_i . Исходному наблюдению-реализации $x_t = (x_{t1}, \dots, x_{tT_t})^T \in R^{T_t}$ длительности T_t поставим в соответствие наблюдение в пространстве оценок ковариационных функций:

$$y_t = (y_{t0}, y_{t1}, \dots, y_{tN})^T \in R^{N+1},$$

$$t = 1, \dots, n, n+1, \dots,$$

где

$$y_{th} = \frac{1}{T_t - h} \sum_{j=i}^{T_t-h} (x_{tj} x_{t, j+h})$$

– непараметрическая оценка ковариаций с лагом h , построенная по x_t .

Определим решающее правило:

$$d(y; \{\hat{\sigma}_i\}_{i \in S}) = \arg \min_{i \in S} |y - \hat{\sigma}_i|, \quad y \in R^{N+1}$$

РП относит наблюдение к такому классу, к "центру" которого оно ближе. В роли "центров" классов здесь выступают $(N + 1)$ – вектора из (6), а в качестве меры близости используется метрика Евклида. Строим оценки для "центров" классов:

$$\hat{\sigma}_i = \left(\sum_{t=1}^n \delta_{d_t^0, i} y_t \right), \quad i \in S$$

IV. ПРИМЕР: ПРОЦЕДУРА КЛАСТЕР-АНАЛИЗА

Построим процедуру кластер-анализа в пространстве МП-оценок параметров авторегрессии, основанную на алгоритме L -средних.

1. По исходной выборке X^n из (6) найдется выборка МП-оценок Y^n , из которой в качестве начальных приближений $\{\hat{\theta}_i^{(0)}\}$, $i \in S$ для «центров» $\{\theta_i^0\}$, $i \in S$ классов $\{\Omega_i\}$ выбираются какие-либо L наблюдений Y_{j_1}, \dots, Y_{j_L} , $j_i \in \{1, \dots, n\}$; $j_i \neq j_k$, $i \neq k \in S$;
2. На l -м шаге ($l = 0, 1, 2, \dots$) производится классификация выборки Y^n :

$$(\hat{d}_t^{(l)}) = \arg \min_{i \in S} |Y_t - \hat{\theta}_i^{(l-1)}|, \quad t = \overline{1, n},$$

т.е. строится оценка $\hat{D}^{(l)} = (\hat{d}_1^{(l)}, \dots, \hat{d}_n^{(l)})$; для D^0 , и уточняются оценки для «центров» классов:

$$\hat{\theta}_i^{(l)} = \left(\sum_{t=1}^n \delta_{\hat{d}_t^{(l)}, i} \right)^{-1} \sum_{t=1}^n \delta_{\hat{d}_t^{(l)}, i} Y_t, \quad i \in S$$

где $\delta_{i,j}$ – символ Кронекера;

3. Итерационный процесс останавливается при достижении на l -м шаге ($2 \leq l < \infty$) равенства $\hat{D}^{(l)} = \hat{D}^{(l-1)}$, и его результатом являются оценки $\hat{D} := \hat{D}^{(l)}$ для вектора истинной классификации D^0 и $\hat{\theta} := \hat{\theta}^{(l)} \in R^{Lp}$ для составного вектора θ^0 параметров авторегрессии θ_i^0 , $i \in S$.

V. ЗАКЛЮЧЕНИЕ

Рассмотрена проблема классификации стационарных временных рядов. Предложены различные подходы к её решению, приведён алгоритм кластерного анализа в пространстве оценок максимального правдоподобия параметров авторегрессии, основанный на алгоритме L -средних.

1. Харин, Ю. С. Теория вероятностей, математическая и прикладная статистика : учеб. пособие / Ю. С. Харин, Н. М. Зуев, Е. Е. Жук. – Минск: БГУ, 2011. – 464 с.
2. Бокс, Дж. Анализ временных рядов. Прогноз и управление / Дж. Бокс, Г. Дженкинс. – М. : Мир, 1974. – 406 с.
3. Андерсон, Т. Статистический анализ временных рядов / Т. Андерсон. – М. : Мир, 1976. – 760 с.