

МАЛОПАРАМЕТРИЧЕСКАЯ МОДЕЛЬ НА ОСНОВЕ БАЗИСНЫХ ФУНКЦИЙ ДЛЯ СТАТИСТИЧЕСКОГО АНАЛИЗА МНОГОМЕРНЫХ ДВОИЧНЫХ ВРЕМЕННЫХ РЯДОВ

С. А. ШИБАЛКО

(Белорусский государственный университет, г. Минск)

Аннотация. В докладе рассматривается задача статистического анализа многомерных двоичных временных рядов. Для решения этой задачи предлагается малопараметрическая модель эргодической цепи Маркова порядка s на основе базисных функций. Построены состоятельные статистические оценки параметров модели и подстановочный алгоритм статистического прогнозирования. Приведены результаты компьютерных экспериментов на модельных и реальных данных.

Ключевые слова: многомерный двоичный временной ряд, цепь Маркова порядка s , малопараметрическая модель, статистическое оценивание параметров, статистическое прогнозирование.

Введение. Цифровизация экономики и всего окружающего мира ведет к увеличению данных в дискретном пространстве состояний с дискретным временем. Для математического описания таких данных используются дискретные, в том числе двоичные, временные ряды. Обзор современного состояния в области статистического анализа многомерных дискретных временных рядов представлен в [1].

Вероятностная модель многомерных двоичных временных рядов. Примем обозначения: \mathbb{Z} – множество целых чисел, \mathbb{R}^k – k -мерное евклидово пространство, $V = \{0, 1\}$ – двоичный алфавит, \mathbb{N} – множество натуральных чисел, штрих у матрицы – символ транспонирования.

Определим на вероятностном пространстве (Ω, \mathcal{F}, P) N -мерный ($N \in \mathbb{N}$) двоичный временной ряд $X_t = (x_{t1}, \dots, x_{tN})' \in V^N$, порожденный семейством условных распределений вероятностей:

$$P\{X_t = J_t \mid \mathcal{F}_{t-1}\} = P\{X_t = J_t \mid X_{t-1} = J_{t-1}, \dots, X_{t-s} = J_{t-s}\}, t \in \mathbb{Z}, \quad (1)$$

где $x_{tl} \in V$ – двоичная (бинарная) случайная величина, задающая компоненту номер l временного ряда в момент времени $t \in \mathbb{Z}$;

$\mathcal{F}_{t-1} = \sigma\{X_\tau : \tau \leq t-1\}$ – σ -алгебра случайных событий, порожденных указанными в скобках случайными векторами;

$J_t = (j_{tl}) \in V^N$ – значение двоичного случайного вектора X_t в момент времени $t \in \mathbb{Z}$;

s – глубина предыстории (памяти процесса), $s \in \mathbb{N}$.

В докладе рассматриваются два случая.

1) *Случай условно независимых компонент*

При фиксированной s -предыстории $X_{t-1} = J_{t-1}, \dots, X_{t-s} = J_{t-s}$ случайные величины X_{t1}, \dots, X_{tN} условно независимы:

$$\begin{aligned} P\{X_t = J_t \mid X_{t-1} = J_{t-1}, \dots, X_{t-s} = J_{t-s}\} = \\ = \prod_{l=1}^N P\{x_{tl} = j_{tl} \mid X_{t-1} = J_{t-1}, \dots, X_{t-s} = J_{t-s}\}, \quad J_t = (j_{tl}) \in V^N, \end{aligned} \quad (2)$$

где условное распределение l -го бита x_{tl} при условии, что фиксирована s -предыстория, представимо в виде:

$$P\{x_{tl} = j_{tl} \mid X_{t-1} = J_{t-1}, \dots, X_{t-s} = J_{t-s}\} = \begin{cases} p_l(J_{t-1:t-s}), & j_{tl} = 1, \\ 1 - p_l(J_{t-1:t-s}), & j_{tl} = 0; \end{cases} \quad (3)$$

здесь $J_{t-1:t-s} = (J'_{t-1}, J'_{t-2}, \dots, J'_{t-s})' \in V^{Ns}$ – составной двоичный вектор-столбец s -предыстории. Заметим, что условная независимость (2) в общем случае не эквивалентна безусловной независимости, так что компоненты X_{t1}, \dots, X_{tN} зависимы между собой через общую для них предысторию.

2) *Случай полностью связанных компонент*

При фиксированной s -предыстории $H = \{X_{t-1} = J_{t-1}, \dots, X_{t-s} = J_{t-s}\}$ случайные величины X_{t1}, \dots, X_{tN} зависимы так, как приведено на формуле:

$$\begin{aligned} P\{X_t = J_t \mid H\} = P\{x_{t1} = j_{t1} \mid H\} \cdot P\{x_{t2} = j_{t2} \mid x_{t1} = j_{t1}, H\} \times \dots \\ \times P\{x_{tN} = j_{tN} \mid x_{t1} = j_{t1}, \dots, x_{tN-1} = j_{tN-1}, H\}, \quad J_t = (j_{tl}) \in V^N, \end{aligned} \quad (4)$$

где условное распределение l -го бита x_{tl} при условии, что фиксирована s -предыстория, представимо в виде:

– для первой компоненты

$$P\{x_{t1} = j_{t1} \mid H\} = \begin{cases} p_1(J_{t-1:t-s}), & j_{t1} = 1, \\ 1 - p_1(J_{t-1:t-s}), & j_{t1} = 0; \end{cases} \quad (5)$$

– для остальных компонент

$$P\{x_{tl} = j_{tl} \mid x_{t1} = j_{t1}, \dots, x_{t-1} = j_{t-1, H}\} = \begin{cases} p_l(x_{t1}, \dots, x_{t-1}, J_{t-1:t-s}), & j_{tl} = 1, \\ 1 - p_l(x_{t1}, \dots, x_{t-1}, J_{t-1:t-s}), & j_{tl} = 0; \end{cases} \quad (6)$$

такую модель будем называть полностью связанной [2].

Модели (2), (3) и (4)–(6) требуют большое количество параметров для потокового задания. Из-за «проклятия размерности» для уменьшения потребления памяти компьютера и времени работы алгоритмов оценивания параметров модели необходимо использовать малопараметрические модели [3].

Малопараметрическая модель на основе базисных функций. Для l -й ($l = 1, \dots, N$) компоненты в докладе определена следующая малопараметрическая модель на основе базисных функций (индекс компоненты l опущен для упрощения обозначений).

$$p = p(J_{t:t-s+1}) = F\left(\sum_{k=1}^m b_k \psi_k(J_{t:t-s+1})\right), J_{t:t-s+1} \in V^{Ns}, \quad (7)$$

где F – некоторая дважды непрерывно дифференцируемая функция распределения $0 < F(x) < 1$;

$B = (b_k) \in \mathbb{R}^m$ – вектор столбец неизвестных параметров модели;

$\psi_k(J_{t:t-s+1})$ – семейство линейно независимых на V^{Ns} базисных функций.

Модель (7) имеет всего $m < m^+ = 2^{Ns}$ неизвестных параметров.

Теорема 1. Векторный двоичный временной ряд X_t , описываемый моделью (7) является N -мерной однородной эргодической цепью Маркова порядка s .

Доказательство. По построению модели (7) переходное распределение вероятностей зависит лишь от предыстории глубины s , что равносильно обобщенному марковскому свойству s -го порядка, поскольку $0 < F(x) < 1$, $x \in \mathbb{R}$, то все элементы матрицы вероятности одношаговых переходов (3) или (5), (6) строго положительны. Это обеспечивает выполнение достаточных условий эргодичности.

Статистическое оценивание параметров модели. Для оценивания вектор-столбца параметров модели (1)–(7) применим FBE-метод [4], основанный на многомерных частотах.

Пусть наблюдается реализация длины T двоичного N -мерного временного ряда:

$$X_{1:T} = (X_1, \dots, X_T) \in V^{TN}.$$

Примем следующие обозначения: $\mathbf{1}\{C\} = \{1, \text{если } C \text{ истинно}, 0 \text{ в противном случае}\}$ – индикаторная функция события C , $F^{-1}(\cdot) : (0, 1) \rightarrow \mathbb{R}^1$ – квантильная

функция $(\mathbf{1}; J'_{t:t-s+1})' = (\mathbf{1}, J'_{t-1} J'_{t-2} \dots J'_{t-s})' \in V^{Ns+1}$ – «расширенный» вектор-столбец, $\Psi(J_{t:t-s+1}) = (\Psi_k(J_{t:t-s+1})) \in \mathbb{R}^{m \times 1}$ – вектор-столбец, состоящий из базисных функций $\Psi_k(J_{t:t-s+1})$.

1) *Случай условно независимых компонент*

$$v_s^T(J_{t:t-s+1}) = \sum_{t=s}^T \mathbf{1}\{X_t = J_t, \dots, X_{t-s+1} = J_{t-s+1}\},$$

$$v_{s+1}^T(\mathbf{1}; J_{t:t-s+1}) = \sum_{t=s}^T \mathbf{1}\{x_{t+1,l} = 1, X_t = J_t, \dots, X_{t-s+1} = J_{t-s+1}\}.$$

2) *Случай полностью связанных компонент*

$$v_s^T(J_{t:t-s+1}) = \sum_{t=s}^T \mathbf{1}\{x_{t+1,l-1} = j_{t+1,l-1}, \dots, x_{t+1,1} = j_{t+1,1}, X_t = J_t, \dots, X_{t-s+1} = J_{t-s+1}\},$$

$$\begin{aligned} v_{s+1}^T(\mathbf{1}; J_{t:t-s+1}) &= \sum_{t=s}^T \mathbf{1}\{x_{t+1,l} = 1, x_{t+1,l-1} = j_{t+1,l-1}, \dots, x_{t+1,1} = \\ &= j_{t+1,1}, X_t = J_t, \dots, X_{t-s+1} = J_{t-s+1}\}, \end{aligned}$$

где $J^{(s)} = \{J_{t:t-s+1} \in V^{Ns}, t = s, s+1, \dots, T : v_s^T(J_{t:t-s+1}) > 0\} \subseteq V^{Ns}$ – подмножество s -предысторий, имеющих ненулевые частоты в $X_{1:T}$.

Построим частотную оценку условной вероятности:

$$\hat{p}(J_{t:t-s+1}) = \begin{cases} \frac{T-s}{T-s+1} \cdot \frac{v_{s+1}^T(\mathbf{1}; J_{t:t-s+1})}{v_s^T(J_{t:t-s+1})}, & J_{t:t-s+1} \in J^{(s)}, \\ \frac{1}{2}, & J_{t:t-s+1} \notin J^{(s)}; \end{cases} \quad (8)$$

и статистики:

$$\hat{u}(J_{t:t-s+1}) = F^{-1}(\hat{p}(J_{t:t-s+1})) \in \mathbb{R}, \quad (9)$$

$$E = (e^k) = \sum_{J_{t:t-s+1} \in J^{(s)}} \hat{u}(J_{t:t-s+1}) \Psi'(J_{t:t-s+1}) \in \mathbb{R}^{m \times 1}, \quad (10)$$

$$D = (d_{ij}) = \sum_{J_{t:t-s+1} \in J^{(s)}} \Psi(J_{t:t-s+1}) \Psi'(J_{t:t-s+1}) \in \mathbb{R}^{m \times m}, D^{-1} = (\bar{d}_{ij}) \in \mathbb{R}^{m \times m}. \quad (11)$$

Теорема 2. Если определитель $|D| \neq 0$ (11), то FBE-оценка для B имеет вид

$$\hat{B} = (b_k) = D^{-1}E,$$

при $T \rightarrow +\infty$ состоятельна, т.е. сходится по вероятности к истинному значению B^0 :

$$\hat{B} \xrightarrow{P} B^0.$$

Подстановочный алгоритм статистического прогнозирования. Используя статистическую оценку \hat{B} параметра модели (7), подстановочный алгоритм оптимального прогнозирования на один шаг определяется явным соотношением:

$$\hat{x}_{t|} = \mathbf{1} \left\{ \hat{p}(X_{t-1:t-s}) - \frac{1}{2} > 0 \right\}, \quad (12)$$

где:

$$\hat{p}(X_{t-1:t-s}) = F\left(\sum_{k=1}^m \hat{b}_k \psi_k(X_{t-1:t-s})\right). \quad (13)$$

Прогнозирование $\hat{x}_{t+1|}$ на следующий шаг осуществляется аналогично (12), только фрагмент $X_{t-1:t-s} = (X_{t-1}, \dots, X_{t-s})$ в (13) заменяется на $(\hat{X}_t, \dots, X_{t-s+1})$, и т.д.

ЛИТЕРАТУРА

1. Fokianos K., Fried R., Kharin Yu., Voloshko V. Statistical analysis of multivariate discrete-valued time series / K. Fokianos, R. Fried, Yu. Kharin, V. Voloshko // J. Multivar. Anal., – 2022. - Vol. 188. – <https://doi.org/10.1016/j.jmva.2021.104805>.
2. Шибалко, С.А. Статистическое оценивание параметров полностью связанных многомерных двоичных временных рядов / С.А. Шибалко // 80-я научная конференция студентов и аспирантов Белорусского государственного университета [Электронный ресурс] : материалы конф., Минск, 10–20 марта 2023 г.: в 3 ч., ч. 1 / Белорус. гос. ун-т ; редкол.: А. В. Блохин (гл. ред.) [и др.]. – Минск : БГУ, 2023. – 1 электрон. опт. диск (CD-ROM). – С. 419-423.
3. Харин, Ю.С. Оптимальность и робастность в статистическом прогнозировании / Ю. С. Харин – Минск: БГУ, 2008. – 263 с.
4. Kharin, Yu. Robust estimation for binomial conditionally nonlinear autoregressive time series based on multivariate conditional frequencies / Yu. Kharin, V. Voloshko // J. Multivar. Anal. – 2021. – Vol. 185. – <https://doi.org/10.1016/j.jmva.2021.104777>.