

# СТАТИСТИЧЕСКИЙ АНАЛИЗ КРЕДИТОСПОСОБНОСТИ В УСЛОВИЯХ СКРЫТОЙ МАРКОВСКОЙ ЗАВИСИМОСТИ РЕЙТИНГОВ

А. Ю. Новопольцев, В. И. Малюгин

Белорусский государственный университет

Минск, Беларусь

E-mail: fpm.novopolc@bsu.by

Предлагаются алгоритмы статистической классификации предприятий на заданное число классов кредитоспособности в пространстве финансовых коэффициентов в условиях ненаблюданной марковской зависимости номеров классов (кредитных рейтингов). В предположении гауссовой модели наблюдений и постоянства параметров модели проводится экспериментальное исследование алгоритмов, учитывающих и не учитывающих зависимость рейтингов для двух вариантов представлений исходной выборки в виде панельных и пространственных данных.

*Ключевые слова:* кредитные рейтинги, пространственные и панельные данные, кластерный анализ, дискриминантный анализ, алгоритм расщепления смеси распределений, скрытая цепь Маркова.

## Модель данных и постановка задачи

Пусть в моменты (периоды) времени  $t = 1, \dots, T$  регистрируется информация относительно финансового состояния  $n$  предприятий одного вида экономической деятельности (отрасли), где  $T$  – длина периода наблюдения, выраженная числом кварталов (лет). Каждое предприятие  $i$  ( $i = 1, \dots, n$ ) на конец отчетного периода  $t$  характеризуется вектором безразмерных финансовых коэффициентов  $x_{i,t} \in \mathbb{R}^N$  [1]. Предполагается, что каждое предприятие  $i$  в любой период  $t$  может быть отнесено к одному из  $L$  классов кредитоспособности. Номер класса является дискретной случайной величиной  $v_{i,t} \in S(L) = \{1, \dots, L\}$ , называемой рейтингом кредитоспособности предприятия. Временной ряд  $\{v_{i,t}\}$  ( $t = 1, \dots, T$ ) описывается скрытой (ненаблюданной) однородной цепью Маркова (ОЦМ) с параметрами [2]:

$$\pi_0 = (\pi_{01}, \dots, \pi_{0L})'; \quad P = (p_{rs}), r, s \in S(L), \quad (1)$$

где  $\pi_{0l} = P\{v_{i,1} = l\} > 0$  – вектор вероятностей начального состояния,  $P$  – матрица миграции рейтингов, элементы которой  $p_{rs} = P\{v_{i,t+1} = s | v_{i,t} = r\} \geq 0$  – вероятности миграции рейтингов предприятий данной отрасли в течение одного периода. Распределение случайного вектора  $x_{i,t}$  зависит от рейтинга  $l \in S(L)$  и для фиксированных  $l, t$  описывается плотностью  $f^{(t)}(u, \theta_l)$  из параметрического семейства:

$$\{f^{(t)}(u, \theta_l)\} (u \in \mathbb{R}^N, \theta_l \in \Theta \in \mathbb{R}^m, t = 1, \dots, T, l \in S(L)). \quad (2)$$

При сделанных модельных предположениях выборка наблюдений  $X = \{x_{i,t}\} (i=1, \dots, n, t=1, \dots, T)$  имеет панельную структуру, т. е. статистические данные  $X$  являются панельными (*panel data*) [3].

При проведении численных экспериментов на модельных данных используются дополнительные предположения о гауссовой модели наблюдений и постоянстве параметров модели, т. е. полагается, что для фиксированных  $l, t (t=1, \dots, T, l \in S(L))$ :  $f^{(t)}(u, \theta_l) \equiv f(u, \theta_l)$  – плотность  $N$ -мерного нормального распределения  $\mathbf{N}_N(\mu_l, \Sigma_l)$ ;  $\theta_l \in \Re^m$  – составной вектор параметров, образованный из параметров  $\mu_l, \Sigma_l$  при условии, что  $v_{i,t} \equiv l$ .

**Задача.** Параметры модели,  $\pi_0, P, \{\theta_l\}$ , а также рейтинги  $\{v_{i,t}\}$  не известны. Задача заключается в их оценивании по наблюдаемым значениям  $\{x_{i,t}\}$  ( $i=1, \dots, n, t=1, \dots, T$ ).

## Алгоритмы оценивания и классификации

Предлагается использовать следующие алгоритмы классификации для двух альтернативных представлений исходной выборки наблюдений.

**Алгоритм 1.** Алгоритм расщепления смеси распределений в случае гауссовой модели наблюдений и скрытой марковской зависимости классов:

$$X = \{x_{i,t}\} (i=1, \dots, n, t=1, \dots, T), x_{i,t} \sim \mathbf{N}_N(\mu_l, \Sigma_l), l \in S(L), \quad (3)$$

позволяющий осуществлять совместное оценивание  $\pi_0, P, \{\theta_l\}$  и  $\{v_{i,t}\}$ ;

**Алгоритм 2.** Алгоритм кластерного анализа выборки пространственных (одномоментных) данных, не учитывающий марковскую зависимость классов:

$$Y = \{y_j\} (j=1, \dots, m), y_j \in \Re^N, m=nT, \quad (4)$$

полученной на основании (3) с помощью перенумерации наблюдений:

$$y_j \equiv x_{i,t}, \quad j=(i-1)T+t, \quad t=1, \dots, T, \quad i=1, \dots, n, \quad (5)$$

предполагающий последовательное оценивание  $\{v_{i,t}\}$  и  $\pi_0, P, \{\theta_l\}$ .

Алгоритмы состоят из следующих основных шагов.

### Шаг 1. Классификация наблюдений из исходных выборок.

Алгоритм 1 на данном шаге в качестве алгоритма классификации выборки  $X$  использует итерационный алгоритм из класса EM-алгоритмов (Expectation-Maximization), учитывающий скрытую марковскую зависимость номеров классов и одновременно оценивающий все параметры модели,  $\pi_0, P, \{\theta_l\}$ , а также рейтинги кредитоспособности  $\{v_{i,t}\}$ . Данный алгоритм является частным случаем алгоритма, представленного в работе [4], с тем отличием, что для каждого состояния цепи Маркова возможно появление наблюдения только из одного распределения, а не из смеси распределений. Обозначим этот частный случай алгоритма через EM HMM (*EM for Hidden Markov Model*). Для оценки рейтингов на последней итерации используется алгоритм Витерби [2].

Алгоритм 2 представляет собой алгоритм  $L$ -средних [5] кластерного анализа выборки  $Y$ . Параметры  $\{\Sigma_l\}, P, \pi_0$  в данном случае вычисляются по классифицирован-

ной выборке  $X = \{x_{i,t}\}$ , полученной в результате обратного преобразования классифицированной выборки  $Y$ :

$$x_{i,t} \equiv y_j, \quad i:(i-1)T < j \leq iT, t = j - (i-1)T, j = 1, \dots, m.$$

Для ковариационных матриц  $\{\Sigma_l\}$  используются несмешанные оценки, а для  $P, \pi_0$  – оценки максимального правдоподобия [2].

Пусть  $\lambda = \{\mu_l, \Sigma_l, l \in S(L); P, \pi_0\}$ , тогда  $\lambda^1$  и  $\lambda^2$  – параметры, оцененные с помощью алгоритмов 1 и 2 соответственно на первом шаге.

### **Шаг 2. Дискриминантный анализ новых наблюдений.**

Для классификации новых наблюдений применяются алгоритмы квадратичного дискриминантного анализа с учетом марковской зависимости классов (КДА-ОЦМ, [6]) и без ее учета (КДА, [5]), которые используют параметры  $\lambda^1$  и  $\lambda^2$  соответственно.

Для оценки влияния марковской зависимости классов на точность классификации с помощью алгоритма 2 используется следующая специальная модификация данного алгоритма.

**Алгоритм 2.1.** Данный алгоритм представляет собой комбинацию алгоритмов 1 и 2: на первом шаге к обучающей выборке  $Y$  применяется алгоритм кластерного анализа, а на втором для классификации новых наблюдений применяется алгоритм КДА-ОЦМ, использующий оценки параметров  $\lambda^2$  для классификации выборки новых данных вида  $X$ .

## **Исследование алгоритмов на модельных данных**

В условиях модельных предположений (1)–(3) с помощью статистического моделирования получена выборка наблюдений  $X = \{x_{i,t}\} (i=1, \dots, n, t=1, \dots, T)$ ,  $x_{i,t} \sim N_2(\mu_l, \Sigma_l) (l \in S(2))$ , представляющая собой смесь  $n=300$  однородных цепей Маркова (ОЦМ) длины  $T=40$  с  $L=2$  состояниями (классами кредитоспособности) и параметрами, определяемыми соотношениями:

$$P = \begin{pmatrix} 0,8 & 0,2 \\ 0,1 & 0,9 \end{pmatrix}, \pi_0 = \begin{pmatrix} 0,4 \\ 0,6 \end{pmatrix}, \mu_1 = \begin{pmatrix} 7,0 \\ 1,0 \end{pmatrix}, \mu_2 = \begin{pmatrix} 1,0 \\ 0,1 \end{pmatrix}, \Sigma = \begin{pmatrix} 3,24 & 0,45 \\ 0,45 & 0,16 \end{pmatrix}.$$

Таким образом, классы кредитоспособности различаются только средними значениями случайного вектора наблюдений  $x_{i,t}$ .

Выбор размерности и значений параметров тестовой модели обусловлен достижением определенного сходства модельных и реальных данных по белорусским промышленным предприятиям, а также ориентацией на действующую в республике методику оценки кредитоспособности [7]. Указанная методика основана на анализе значений двух коэффициентов и классификации предприятий на два класса: кредитоспособных ( $\Omega_1$ ) и некредитоспособных ( $\Omega_2$ ).

Для исследования описанных алгоритмов на первом шаге используется неклассифицированная обучающая выборка, для которой  $T_1 = 30$ , а на втором – экзаменационная выборка, для которой  $T_2 = 10 (T = T_1 + T_2)$ .

Для всех алгоритмов на первом шаге применяется одна и та же случайная начальная классификация с равновероятным распределением классов (случай отсутствия априорной информации о кредитоспособности предприятий). Для алгоритма 1 также используется параметр сходимости  $\varepsilon = 0,0001$  с условием остановки:

$$LL^{[k]} \geq LL^{[k-1]} \wedge (LL^{[k]} - LL^{[2]}) < (1 + \varepsilon)(LL^{[k-1]} - LL^{[2]}),$$

где  $LL^{[k]}$  – значение логарифмической функции правдоподобия на  $k$ -ой итерации.

Введем обозначения:  $C$ -1 и  $C$ -2 – истинные классификации, полученные в результате моделирования, для обучающей и экзаменационной выборок соответственно;  $C1$ -1 и  $C2$ -1 – классификации обучающей выборки, полученные на первом шаге алгоритмов 1 и 2 соответственно, а  $C1$ -2,  $C2$ -2 и  $C21$ -2 – классификации экзаменационной выборки на втором шаге алгоритмов 1, 2 и 2.1. Заметим, что результаты алгоритмов 2 и 2.1 на первом шаге совпадают, поэтому рассматриваются только результаты алгоритма 2. На основе перечисленных классификаций были рассчитаны средние (по отрасли) рейтинги, которые представляют собой средние значения номеров классов (рейтингов) в каждый момент времени. Для средних рейтингов приняты соответствующие обозначения  $RC$ -1,  $RC$ -2,  $RC1$ -1,  $RC1$ -2,  $RC2$ -1,  $RC2$ -2,  $RC21$ -2.

Для оценивания точности полученных результатов используются статистики:  $r$  – безусловная ошибка классификации для рейтингов;  $MAPE$  – средняя абсолютная ошибка в процентах (*Mean Absolute Percentage Error*) для средних рейтингов; показатели точности оценивания параметров модели (отклонения оценок от истинных значений)  $\delta_x = \|\hat{\theta} - \theta\|$ ,  $\delta_P = \|\hat{P} - P\|$ , где  $\|\cdot\|$  – евклидова норма, а  $\hat{\theta}$  и  $\hat{P}$  – соответственно составные векторы оценок параметров  $\{\mu_l, \Sigma_l\}$  и  $P$ .

Результаты численных экспериментов представлены в табл. 1–2, а также на рис. 1.

Таблица 1  
Анализ точности классификации

$r, \%$					$MAPE, \%$				
$T_1 = 30$		$T_2 = 10$			$T_1 = 30$		$T_2 = 10$		
$C1$ -1	$C2$ -1	$C1$ -2	$C2$ -2	$C21$ -2	$RC1$ -1	$RC2$ -1	$RC1$ -2	$RC2$ -2	$RC21$ -2
2,31	5,07	2,00	5,47	2,63	0,44	1,34	0,52	1,76	0,94

Таблица 2  
Точность оценки параметров

<i>EM HMM</i>		<i>L</i> -средних	
$\delta_x$	$\delta_P$	$\delta_x$	$\delta_P$
0,0879	0,0176	0,6113	0,1617

Оценка вероятности ошибки байесовского решающего правила (с учетом марковской зависимости, [6]) равна 2,23 % для обучающей и 1,97 % для экзаменационной выборки, что немногим лучше результатов Алгоритма 1 (см. табл. 1,  $C1$ -1 и  $C1$ -2). Согласно табл. 1 и рис. 1, алгоритм 1 показал самую высокую точность классификации и оценивания параметров. Алгоритм 2.1 на втором шаге также продемонстрировал достаточно высокую точность классификации, практически сопоставимую с Алгоритмом 1 (имеет место увеличение вероятности ошибки всего на 0,63 %). В то время как точность оценивания параметров для алгоритма *L*-средних существенно (почти на порядок) ниже относительно алгоритма *EM HMM* (см. табл. 2).

На основании полученных результатов можно сделать важный для практики вывод: в рамках используемых модельных предположений для классификации исходной выборки вместо трудоемкого алгоритма EM HMM можно применять более простой в вычислительном отношении алгоритм  $L$ -средних, используя при этом представление панельных данных в виде пространственной (одномоментной) выборки. В условиях большой размерности задачи (больших значений  $L, N, n$  и  $T$ ) такая замена алгоритмов может позволить существенно сократить вычислительные затраты при сравнительно малых потерях точности результатов.

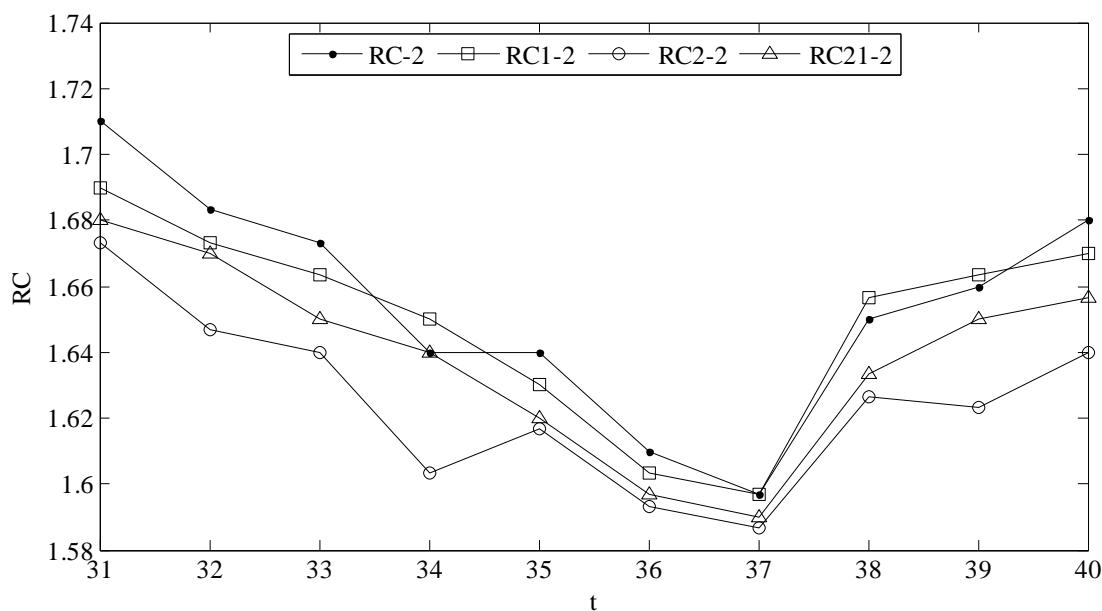


Рис. 1. Средние рейтинги для экзаменационной выборки

## Библиографические ссылки

1. Малюгин В. И., Корчагин О. И., Гринь Н. В. Исследование эффективности алгоритмов классификации заемщиков банков на основе балансовых коэффициентов // Банковский Вестник. 2009. № 7. С. 26–33.
2. Bhar R., Hamori S. Hidden Markov models: Application to financial economics. Dordrecht: Kluwer Academic Publishers, 2004.
3. Hsiao C. Analysis of Panel Data. NY: Cambridge University Press, 2002.
4. Bilmes Jeff A. A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models. Technical Report TR-97-021. University of California at Berkeley, International Computer Science Institute and Computer Science Division, 1998.
5. Харин Ю. С., Малюгин В. И., Абрамович М. С. Математические и компьютерные основы статистического анализа данных и моделирования: учеб. пособие. Минск : БГУ, 2008.
6. Харин Ю. С. Обнаружение разладок марковского типа в случайной последовательности многомерных наблюдений // Статистические проблемы управления. Вильнюс. 1984. В. 65. С. 225–235.
7. Инструкция по анализу и контролю за финансовым состоянием и платежеспособностью субъектов предпринимательской деятельности (в ред. постановления Министерства финансов, Министерства экономики и Министерства статистики и анализа Республики Беларусь от 8 мая 2008 г. № 79/99/50).