

22. Due to the resort tax in the regions, the number of tourists was counted. The number of holidaymakers in Sochi fell by 39%, according to official statistics. (In Russ.). URL: <https://www.rbc.ru/business/28/02/2019/5c7572839a794782ad4e2d7b>

23. In the small hotels of the Kuban were not ready for the resort collection. (In Russ.). URL: <https://www.tourdom.ru/news/v-nebolshikh-otelyakh-kubani-okazalis-ne-gotovy-k-kurortnomu-sboru.html>

24. Experts: “In hotels, they evade the collection of resort fees”. (In Russ.). URL: <https://www.tourdom.ru/news/eksperty-v-gos-tinitisakh-uklonyayutsya-ot-vzimaniya-kurortnogo-sbora.html>

25. In the Kuban adopted a law on the financing of facilities through resort fees. (In Russ.). URL: <https://ria.ru/20190327/1552168644.html>

26. The Stavropol Territory plans to increase revenues from resort fees by 1.3 times in 2019. (In Russ.). URL: <https://tourism.interfax.ru/ru/news/articles/58243/>

27. What will tourists fork out for? (In Russ.). URL: <https://www.pnp.ru/economics/na-cto-raskoshelyatsya-turisty.html>

28. Putin signed the law on the introduction of a resort fee. (In Russ.). URL: <https://crimea.ria.ru/society/20170731/1111366640.html>

29. Everything in assembly: at the popular resorts of Russia, vacationers are still asked to pay extra. (In Russ.). URL: <https://iz.ru/873937/evgenii-priemskai/vse-v-sbore-na-populiarnykh-kurortakh-rossii-otdykhaiushchikh-po-prezhnemu-poprosiat-doplatit>

30. In Essentuki, 159 tourists refused to pay the resort fee. (In Russ.). URL: <https://newstracker.ru/news/economy/21-01-2019/v-essentukah-159-turistov-otkazalis-platit-kurortnyy-sbor>

31. Crimea decided to cancel the resort fee for 2019. (In Russ.). URL: <https://www.vedomosti.ru/politics/news/2019/04/05/798424-krim-reshil-otmenit-kurortnii-sbor-2019-god>

32. In Crimea, the negative impact of tourist tax was recognized. (In Russ.). URL: <https://www.tourdom.ru/news/v-krymu-priznali-negativnoe-vliyanie-turisticheskogo-sbora-na-potok.html>

Как цитировать статью: Тищук М. О., Щепкова И. В. Анализ предварительных итогов эксперимента по взиманию курортного сбора в регионах РФ // Бизнес. Образование. Право. 2019. № 4 (49). С. 289–296. DOI: 10.25683/VOLBI.2019.49.456.

For citation: Tishchuk M. O., Shchepkova I. V. Analysis of preliminary results of an experiment on resort fee collecting in some Russian regions. *Business. Education. Law*, 2019, no. 4, pp. 289–296. DOI: 10.25683/VOLBI.2019.49.456.

УДК 336
ББК 65

DOI: 10.25683/VOLBI.2019.49.429

Chelyshev Dmitriy Sergeevich,
Post-graduate, 08.00.13 “Mathematical and instrumental methods in economics”,
Department of Mathematical Methods in Economics,
Plekhanov Russian University of Economics,
Moscow, Russian Federation,
e-mail: mr.chelyshev@gmail.com

Чельшев Дмитрий Сергеевич,
аспирант направления 08.00.13 «Математические и инструментальные методы экономики»,
кафедра математических методов в экономике,
Российский экономический университет им. Г. В. Плеханова,
г. Москва, Российская Федерация,
e-mail: mr.chelyshev@gmail.com

КЛАССИФИКАЦИЯ РОССИЙСКИХ БАНКОВ НА ОСНОВЕ ВНУТРЕННИХ ПОКАЗАТЕЛЕЙ ОТЧЕТНОСТИ

RUSSIAN BANKS CLASSIFICATION BASED ON THE INTERNAL INDICATORS OF REPORTING

08.00.13 – Математические и инструментальные методы экономики

08.00.13 – Mathematical and instrumental methods in economics

В данной статье приведено сравнение подходов к оценке влияния внутренних показателей отчетности российских банков на оценку финансовой устойчивости и формирование кредитного рейтинга. В качестве показателей были использованы показатели годовых отчетов российских банков из разделов «Бухгалтерский баланс» и «Отчет о движении денежных средств». Для оценки вероятности дефолта российских банков были использованы данные долгосрочного международного рейтинга в иностранной валюте Moody's Investors Services. Кредитные рейтинги представляют собой мнения о кредитном риске. Рейтинг выражает мнение агентств о способности и готовности эмитента, например корпорации, государства или муниципального образования, выполнять финансовые обязательства своевременно и полностью. Каждое рейтинговое агентство имеет свою методологию оценки кредитного

рейтинга, однако они, как правило, носят описательный характер, то есть невозможно сказать, какой фактор оказывает большее влияние на финансовую устойчивость банка. Методы кластеризации «без учителя» позволяют объективно проанализировать внутренние показатели отчетности российских банков с целью оценки финансовой устойчивости организации. В данной работе будет представлено сравнение трех методов: метода k-средних, метода k-медоид, метода гауссовых смесей. Сравнение полученных кластеров и фактических данных кредитных рейтингов позволит выявить показатели, которые оказывают наибольшее и наименьшее влияние. Ввиду того, что все методы кластеризации «без учителя» относятся к робастным методам классификации, исходную выборку данных требуется подготовить с помощью процедуры сокращения размерности пространства признаков.

his article compares approaches to assessing the impact of internal reporting indicators of Russian banks on assessing financial stability and the formation of a credit rating. Figures from annual reports of Russian banks in the balance sheet section and cash flow statement section were used as factors for model. In order to assess the probability of default of Russian banks, Moody's Investors Services's long-term international foreign currency rating was used. Credit ratings are opinions about credit risk. The rating expresses opinions of agencies on the ability and readiness of the issuer, for example, a corporation, a state or a municipality, to fulfill financial obligations in a timely and complete manner. Each rating agency has its own methodology to assess the credit rating, but usually it is a qualitative measure, as a result, it is impossible to find out which factor has a greater impact on the financial stability of the bank. Unsupervised training methods allow analyzing the internal reporting indicators of Russian banks objectively in order to assess the financial sustainability of an organization. This paper presents a comparison of three methods - the k-means method, the k-medoid method, the Gaussian mixtures model. A comparison of the obtained clusters and the actual credit ratings will allow us to identify the indicators that have the greatest and the least impact. Because all unsupervised training methods are robust classification methods, the initial data sampling needs to be prepared by a feature space reduction procedure.

Ключевые слова: оценка дефолта банка, обучение «без учителя», классификация, метод k-средних, метод k-медоид, метод гауссовых смесей, финансовая устойчивость, государственные российские банки, частные российские банки, методы многомерного статистического анализа, кредитный рейтинг.

Keywords: bank default assessment, unsupervised training, classification, k-mean method, k-medoids method, Gaussian mixture model, financial sustainability, public Russian banks, private Russian banks, multivariable analysis, credit rating.

Введение

Прогнозирование кредитного риска является одной из актуальных тем в современной финансовой сфере, поскольку банковский регулятор увеличивает значимость внутренних и внешних кредитных рейтингов.

Целесообразность разработки данной темы обусловлена тем, что процесс кредитного скоринга очень важен для инвесторов в процессе разграничения «хороших» и «плохих» банков в терминах вероятности их дефолта.

Изученность проблемы. Статистические методы кредитного скоринга созданы для предсказания вероятности того, что банк не сможет выполнить финансовые обязательства перед своими заемщиками. Исторически дискриминантный анализ и логистическая регрессия были широко использованы с целью построения системы оценки банков [1, 2]. Альтман [3] был первым, кто предложил использовать статистические методы для предсказания вероятности дефолта организации, рассчитывая ее с помощью стандартного дискриминантного анализа. Спустя десять лет Альтман [4] модифицировал его оценку путем расширения размера обучающей выборки. Кроме этого базового метода, более точные методы, такие как логистическая регрессия, нейронные сети и экспертные системы, были разработаны и широко применяются как для практических, так и для теоретических целей анализа вероятности дефолта организации [5, 6].

Цель данной работы — выявление показателей внутренней отчетности, которые оказывают наибольшее влияние на формирование кредитного рейтинга банка.

Задачи данной работы:

- отбор факторов, влияющих на финансовую устойчивость российских банков;
- классификация государственных и частных российских банков на основе экономических показателей внутренней отчетности;
- сравнение методов кластеризации российских банков на основе моделей k -средних, k -медоид, гауссовых смесей.

Научная новизна исследования заключается в анализе подходов к оценке кредитного рейтинга российских банков и их сравнении.

Практическая и теоретическая значимость заключается в том, что предложенные оценки кредитных организаций на основе строго математического аппарата, в отличие от оценок рейтинговых агентств, в которых учитываются в некотором смысле субъективные мнения экспертов, могут быть взяты за основу в принятии решений по инвестированию средств.

Анализируемая выборка

Для оценки финансовой устойчивости российских банков в данной работе были выбраны данные долгосрочного международного рейтинга в иностранной валюте Moody's Investors Services.

В качестве показателей были использованы показатели из годовых отчетов банков. Показатели бухгалтерского баланса:

- активы: «денежные средства», «средства кредитных организаций в Центральном банке Российской Федерации» и др.;
- пассивы: «кредиты», «депозиты и прочие средства Центрального банка Российской Федерации», «средства кредитных организаций» и др.;
- источники собственных средств: «средства акционеров (участников)», «собственные акции (доли), выкупленные у акционеров (участников)», и др.;
- внебалансовые обязательства: «безотзывные обязательства кредитной организации, выданные кредитной организацией гарантии и поручительства», «условные обязательства некредитного характера».

Показатели для моделирования из отчета о движении денежных средств:

- «процентные доходы всего», в том числе: «от размещения средств в кредитных организациях», «от ссуд, предоставленных клиентам (некредитным организациям)», «от оказания услуг по финансовой аренде (лизингу)», «от вложений в ценные бумаги»;
- «процентные расходы всего», в том числе: «по привлеченным средствам кредитных организаций», «по привлеченным средствам клиентов (некредитных организаций)», «по выпущенным долговым обязательствам»;
- «чистые процентные доходы (отрицательная процентная маржа)»;
- «чистые доходы от операций с ценными бумагами»;
- «чистые доходы от операций с иностранной валютой»;
- «чистые доходы от переоценки иностранной валюты»;
- «комиссионные доходы»;
- «комиссионные расходы» и др.

Были собраны годовые данные по 81 банку, которым был присвоен долгосрочный международный рейтинг в иностранной валюте Moody's Investors Service за период с 2011 по 2017 г. [7].

Для получения устойчивой классификации банков было проведено их робастное оценивание. С целью сохранения

информативности был предложен подход на основе метода главных компонент. В результате применения комплекса методов (метод главных компонент, метод кластерного анализа, метод корреляционно-дисперсионного анализа) удалось нивелировать «эффект масштаба» и произвести снижение признакового пространства [8].

Список отобранных признаков:

- «Денежные средства»;
- «Обязательные резервы»;
- «Средства клиентов (некредитных организаций)»;
- «Вклады физических лиц»;
- «Всего источников собственных средств»;
- «От ссуд, предоставленных клиентам (некредитным организациям)»;
- «Прочие операционные расходы».

Далее в статье к редуцированному пространству будут применены три метода классификации без учителя. С помощью каждого отдельного метода были сформированы кластеры, исходя из структуры показателей внутренней отчетности. Данные кластеризации будут сравнены с кредитными рейтингами с целью выявления показателей, которые оказывают наибольшее влияние

на формирование кластеризации. Выявить таковые показатели позволит анализ коэффициентов дискриминантной функции, которые будут получены после проведения дискриминантного анализа [9, 10].

Метод *k*-средних. Целью данного метода кластерного анализа является разделение *m* наблюдений (из пространства R^n) на *k* кластеров, при этом каждое наблюдение относится к тому кластеру, к центру (центроиду) которого оно ближе всего.

В качестве меры близости используется Евклидово расстояние:

$$p(x, y) = \|x - y\| = \sqrt{\sum_{p=1}^n (x_p - y_p)^2}, \quad (1)$$

где $x, y \in R^n$ [11].

Проведем кластеризацию методом *k*-средних. Рассмотрим такой метод классификации объектов без учителя, как метод *k*-средних [12, 13].

Сравним полученную кластеризацию с кредитными рейтингами, присвоенными банкам рейтинговым агентством Moody's Investors [14] (табл. 1).

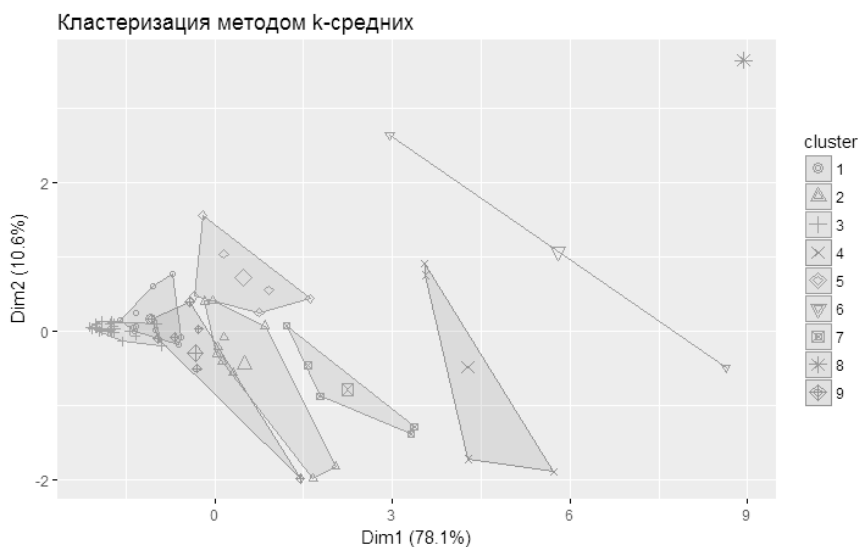


Рис. 1. Кластеризация редуцированного пространства методом *k*-средних

Таблица 1
Разбиение редуцированного пространства методом *k*-средних

Рейтинг	Кластер								
	1	2	3	4	5	6	7	8	9
Ba2	3		1		1				
Ba3	1				1				1
B1	4			1	2	1		1	2
B2	2	1		1	1	3	1		3
B3	16					3			3
Сaa1									1
Сaa2		2							
Сaa3					1	2			
Withdrawn	2		1	3	1	2			2

Так как в один кластер попадают объекты разных кредитных рейтингов, то проверим вероятность попадания данного объекта в кластер при помощи дискриминантного

анализа. Для начала проранжируем кластеры от «наилучшего» к «наихудшему» (табл. 2).

Таблица 2
Разбиение редуцированного пространства методом *k*-средних

Рейтинг	Кластер								
	3	5	1	4	9	8	7	2	6
Ba2	1	1	3						
Ba3		1	1		1				
B1		2	4	1	2	1			1
B2		1	2	1	3		1	1	3
B3			16		3				3
Сaa1					1				
Сaa2								2	
Сaa3			1						2
Withdrawn	1	1	2	3	2				2

Проведем ручную корректировку некоторых объектов (банков), которые не соответствуют своему кластеру, затем проведем дискриминантный анализ и проанализируем коэффициенты дискриминантных функций с целью выявления факторов, которые большего всего влияют на классификацию объектов (для лучшей визуализации коэффициенты умножены на 10⁶) (табл. 3).

Наибольшее влияние оказывает показатель «Денежные средства», данная статья бухгалтерского баланса отражает наиболее ликвидный актив. Чем больше объем данной статьи, тем выше устойчивость компании, так как она может быстро погасить возникающие обязательства перед контрагентами. Низкое влияние оказывает показатель «прочие операционные расходы», так как в сравнении с другими статьями расходной части баланса она нематериальна.

Таблица 3

Коэффициенты дискриминантных функций

Признак	LD1	LD2	LD3	LD4	LD5	LD6	LD7
Денежные средства	0,1224	0,0791	0,1908	0,0914	0,0532	0,1796	0,2611
Обязательные резервы	-0,3743	-1,3660	1,6690	2,0650	0,5585	-1,5200	-0,4578
Средства клиентов (некредитных организаций)	-0,0691	0,0168	-0,0171	-0,0054	0,0016	0,0167	-0,0063
Вклады физических лиц	-0,0022	-0,0569	-0,0109	-0,0035	-0,0266	-0,0081	-0,0142
Всего источников собственных средств	-0,0301	0,0570	0,0617	-0,0763	-0,0838	-0,0295	-0,0140
От ссуд, предоставленных клиентам (некредитным организациям)	0,0665	-0,0050	-0,0233	-0,0004	0,0539	-0,1034	0,1575
Прочие операционные расходы	-0,0686	0,0155	0,0125	-0,0457	0,1149	0,0673	-0,1287

Метод *k*-медоид. Для сокращения влияния шума и обособленных точек пространства на результат кластеризации алгоритм *k*-медоид, в отличие от *k*-средних, использует для представления центра кластера не центр масс, а представительный объект — один из объектов кластера. Как и в методе *k*-средних, сначала произвольным образом выбирается *k* представительных объектов. Каждый из оставшихся объектов объединяется в кластер с ближайшим представительным объектом. Затем итеративно для каждого представительного объекта производится его замена произвольным непредставительным объектом пространства данных. Процесс замены продолжается до тех пор, пока улучшается качество результирующих кластеров. Качество кластеризации определяется суммой отклонений между каждым объектом и представительным объектом соответствующего кластера, которую метод стремится минимизировать. То есть итерации продолжаются до тех пор, пока в каждом кластере его представительный объект не станет медоидом — наиболее близким к центру кластера объектом. Алгоритм плохо масштабируем для обработки больших объемов данных.

Алгоритм метода кластеризации *k*-медоид:

1. Для заданного кластера находится объект кластера *C* путем минимизации суммарного расстояния до других точек данного кластера:

$$i_k^* = \operatorname{argmin}_{c(i^*)=k} D(x_i, x_{i^*}). \tag{2}$$

Далее получается текущий вектор центров кластера $m_k = x_{i_k^*}, k = 1, 2, \dots, K$.

2. Используя полученный вектор центров кластера $\{m_1, \dots, m_k\}$, минимизируем функцию ошибок, соотнося каждое значение с текущим центром каждого кластера:

$$\hat{N}(i) = \operatorname{argmin}_{1 \leq k \leq K} D(x_i, x_k) \tag{3}$$

3. Повторять шаги 1 и 2, пока вектор центров не перестанет преобразовываться.

Метод требует, чтобы все переменные являлись количественными, метод *k*-медоид, как и метод *k*-средних, требует задачи количества кластеров для инициализации алгоритма. Начальный

шаг алгоритма *k*-медоид можно задавать вектором $\{m_1, \dots, m_k\}$ или $\{i_1, \dots, i_k\}$ либо задавая величину $C(i)$. Обычно задача вектора центров более эффективна. На каждом этапе новые центры i_k минимизируют критерии (2) и (3), исходя из предыдущих центров i_1, \dots, i_{k-1} . Алгоритм состоит из *K* шагов, что соответствует количеству заданных кластеров. Количество задаваемых кластеров зависит от цели исследования. К примеру, компания может нанять *K* продавцов, и целью является разделить клиентскую базу между *K* продавцами таким образом, чтобы клиенты одной группы были наиболее схожи между собой. Чаще всего кластерный анализ применяется, когда требуется определить «натуральное» разделение клиентов на соответствующие группы. В случае, если количество кластеров невозможно определить, их количество можно определить статистическим подходом [15].

Методы, основанные на исходных данных, оценивают количество кластеров K^* , анализируя неподobie W_k как функцию от количество кластеров *K*. Значение функции W_k рассчитывается для $K \in \{1, 2, \dots, K_{\max}\}$. Величины $\{W_1, \dots, W_{K_{\max}}\}$ уменьшаются с увеличением *K*.

Проведем кластеризацию методом *k*-медоид. Рассмотрим следующий метод классификации объектов без учителя под названием «метод *k*-медоид» [12, 13, 16].

Проведем кластеризацию методом *k*-медоид и отобразим результат на графике (рис. 2, табл. 4).

Таблица 4

Разбиение редуцированного пространства методом *k*-медоид

Рейтинг	Кластер								
	1	2	3	4	5	6	7	8	9
Ba2	1				3				1
Ba3	1		1		1				
B1	1		3	2	3	1		1	
B2	1	2	4	2	2	1			
B3			3	4	15				
Caa1			1						
Caa2		2							
Caa3	1			2					
Withdrawn	1		2	3	1	3	1		

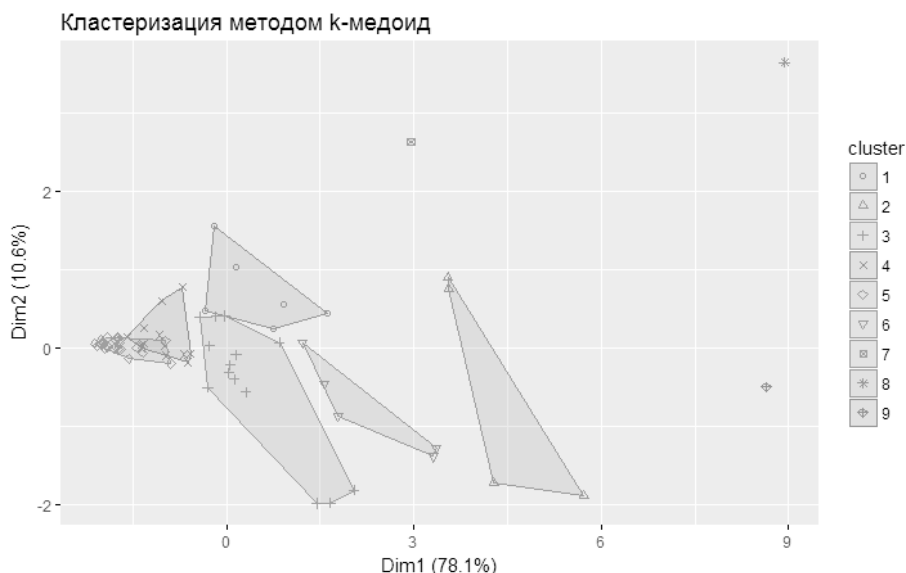


Рис. 2. Кластеризация методом k-меоид редуцированного пространства

Так как в один кластер попадают объекты разных кредитных рейтингов, то проверим вероятность попадания данного объекта в кластер при помощи дискриминантного анализа. Для начала проранжируем кластеры от «наилучшего» к «наихудшему» (табл. 5).

Проведем ручную корректировку некоторых объектов (банков), которые не соответствуют своему кластеру, затем проведем дискриминантный анализ и проанализируем коэффициенты дискриминантных функций с целью выявления факторов, которые больше всего влияют на классификацию объектов (для лучшей визуализации коэффициенты умножены на 10⁶) (табл. 6).

Наибольшее влияние на кластеризацию банков оказывают признаки «денежные средства» и «обязательные резервы». Чем больше объем денежных средств, чем выше устойчивость компании, так как она может быстро погасить возникающие обязательства перед контрагентами.

Таблица 5

Разбиение редуцированного пространства методом k-меоид

Рейтинг	Кластер								
	9	8	1	5	3	6	2	4	7
Ba2	1		1	3					
Ba3			1	1	1				
B1		1	1	3	3	1		2	
B2			1	2	4	1	2	2	
B3				15	3			4	
Caa1					1				
Caa2							2		
Caa3			1					2	
Withdrawn			1	1	2	3		3	1

Таблица 6

Коэффициенты дискриминантных функций

Признак	LD1	LD2	LD3	LD4	LD5	LD6	LD7
Денежные средства	0,0846	-0,0914	0,1368	-0,1875	-0,0401	0,1646	-0,2660
Обязательные резервы	0,1409	-1,4870	-0,3149	-2,6390	-0,3641	-1,5150	0,6085
Средства клиентов (некредитных организаций)	-0,0742	0,0359	-0,0017	0,0130	0,0010	0,0173	0,0051
Вклады физических лиц	0,0148	-0,0589	-0,0343	0,0113	0,0252	-0,0099	0,0146
Всего источников собственных средств	-0,0247	-0,1329	0,1304	0,0523	0,0554	-0,0365	0,0071
От ссуд, предоставленных клиентам (некредитным организациям)	0,0693	0,0494	-0,0510	0,0003	-0,0713	-0,1026	-0,1462
Прочие операционные расходы	-0,0794	0,0090	0,0285	0,0107	-0,1046	0,0861	0,1284

Метод гауссовых смесей. Модель гауссовых смесей представляет собой взвешенную сумму M компонент и может быть записана выражением [17]:

$$p(\bar{x}|\alpha) = \sum_{i=1}^M p_i b_i(\bar{x}), \quad (4)$$

где \bar{x} — D-размерный вектор случайной величин $b_i(\bar{x})$, $i = 1, \dots, M$ — функции плотности распределения составляющих модели и p_i , $i = 1, \dots, M$ — веса компо-

нентов модели. Каждый компонент является D-мерной гауссовой функцией распределения вида

$$b_i(\bar{x}) = \frac{1}{(2\pi)^{D/2} |\Sigma_i|^{1/2}} \exp\left\{-\frac{1}{2}(\bar{x} - \bar{\mu}_i)\right\}, \quad (5)$$

где $\bar{\mu}_i$ — вектор математического ожидания; Σ_i — ковариационная матрица. Веса смеси удовлетворяют выражению $\sum_{i=1}^M p_i = 1$.

Полностью модель гауссовой смеси определяется векторами математического ожидания, ковариационными матрицами и весами смесей для каждого компонента модели. Эти параметры все вместе записываются в виде:

$$\alpha = \{p_i, \mu_i, \Sigma_i\}, i = 1, \dots, M. \tag{6}$$

Проведем кластеризацию с помощью модели гауссовых смесей. Отобразим результат на графике [13, 18] (рис. 3).

Так как в один кластер попадают объекты разных кредитных рейтингов, то проверим вероятность попадания данного объекта в кластер при помощи дискриминантного анализа. Для начала проранжируем кластеры от «наилучшего» к «наихудшему» (табл. 7, 8).

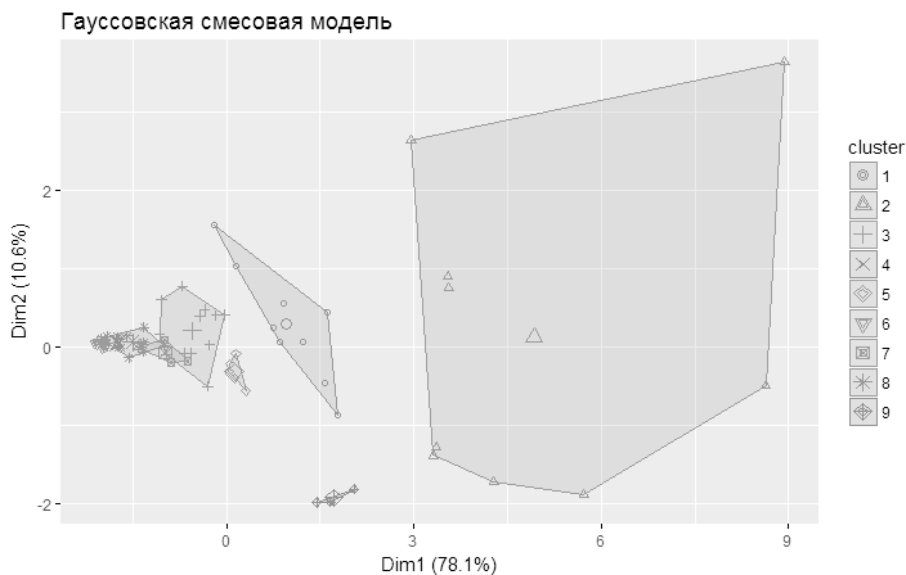


Рис. 3. Кластеризация моделью гауссовых смесей редуцированного пространства

Проведем ручную корректировку некоторых объектов (банков), которые не соответствуют своему кластеру, затем проведем дискриминантный анализ и проанализируем коэффициенты дискриминантных функ-

ций с целью выявления факторов, которые большего всего влияют на классификацию объектов (для лучшей визуализации коэффициенты умножены на 10⁶) (табл. 9).

Таблица 7

Разбиение редуцированного пространства с помощью модели гауссовых смесей

Рейтинг	Кластер								
	1	2	3	4	5	6	7	8	9
Ba2	1	1					2	1	
Ba3			1					1	1
B1	3	1	3			1	1	2	
B2	1	3	2	1	1	1		2	1
B3			2	8	3	6		3	
Saa1									1
Saa2		2							
Saa3	1		2						
Withdrawn	3	2	2		1		1	2	

Таблица 8

Разбиение редуцированного пространства с помощью модели гауссовых смесей

Рейтинг	Кластер								
	7	8	3	1	2	9	6	4	5
Ba2	2	1		1	1				
Ba3		1	1			1			
B1	1	2	3	3	1		1		
B2		2	2	1	3	1	1	1	1
B3		3	2				6	8	3
Saa1						1			
Saa2					2				
Saa3			2	1					
Withdrawn	1	2	2	3	2				1

Коэффициенты дискриминантных функций

Таблица 9

Признак	LD1	LD2	LD3	LD4	LD5	LD6	LD7
Денежные средства	0,0438	-0,1933	0,1606	-0,0098	0,0308	0,3097	0,0862
Обязательные резервы	-1,4830	-0,9017	-0,5372	2,5640	1,1130	0,0656	-0,5582
Средства клиентов (некредитных организаций)	0,0031	0,0056	-0,0103	-0,0220	0,0012	-0,0021	0,0107
Вклады физических лиц	-0,0135	-0,0247	-0,0197	0,0028	-0,0240	-0,0176	-0,0231
Всего источников собственных средств	0,0274	-0,0415	0,0826	-0,0365	0,0140	-0,0445	-0,0785
От ссуд, предоставленных клиентам (некредитным организациям)	-0,0648	0,0367	0,1414	0,1108	-0,0700	0,0136	0,0850
Прочие операционные расходы	-0,1116	0,2219	-0,1147	-0,0618	0,0820	0,0214	-0,0192

Наибольшее влияние на кластеризацию оказывает признак «обязательные резервы». Обязательное резервирование вводится для обеспечения обязательств банков по размещенным депозитам, а также для регулирования объема денежной массы, находящейся в обращении.

Заключение

В статье были рассмотрены три подхода к оценке влияния внутренних показателей российских банков на вероятность дефолта. В качестве показателя вероятности дефолта российских банков были использованы кредитные рейтинги, которые присваиваются международным рейтинговым агентством Moody's Investors Services. Исходное пространство

признаков было редуцировано с целью возможности применения методов k -средних, k -медоид и модели гауссовых смесей. Анализ с помощью методов k -средних и k -медоид позволяет сказать, что наибольшее влияние на формирование кредитного рейтинга оказывает признак «денежные средства». В то же время анализ с помощью модели гауссовых смесей позволил сказать, что наибольшее влияние оказывает признак «обязательные резервы», что не противоречит полученным результатам, так как данный признак является вторым по влиянию согласно методу k -медоид. С учетом этого можно утверждать, что наибольшее влияние оказывают признаки «денежные средства» и «обязательные резервы», а наименьшее — «прочие операционные расходы».

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Hand D. J., Henley W. E. Statistical Classification Methods in Consumer Credit Scoring: A Review // *Journal of Royal Statistical Society*. 1997. Vol. 160. Pp. 523—541.
2. Hand D. J. Data Mining: New Challenges for Statisticians // *Social Science Computer Review*. 2000. Vol. 18. No. 4. Pp. 442—449.
3. Altman E. I. et al. Financial distress prediction in an international context: A review and empirical analysis of Altman's Z-score model // *Journal of International Financial Management & Accounting*. 2017. Vol. 28. No. 2. Pp. 131—171.
4. Altman E. I., Haldeman R. G., Narayanan P. ZETATM analysis A new model to identify bankruptcy risk of corporations // *Journal of Banking & Finance*. 1977. Vol. 1. No. 1. Pp. 29—54.
5. Бирюков А. Н. Разработка показателей авторской модели в методике оценки угрозы банкротства предприятия // *Современные научные исследования и разработки*. 2018. № 1(18). С. 55—65.
6. Lepetit L., Strobel F. Bank insolvency risk and Z-score measures: A refinement // *Finance Research Letters*. 2015. Vol. 13. Pp. 214—224. doi: 10.1016/j.frl.2015.01.001
7. Информационное агентство Spark. URL: <http://www.spark-interfax.ru/>
8. Чельшев Д. С. Методы снижения размерности пространства в условиях нечеткой информации // *Advanced Science: сборник статей IV Международной науч.-практич. конф.*
9. Чельшев Д. С. Моделирование вероятности дефолта российских банков // *Бизнес. Образование. Право*. 2019. № 2 (47). С. 245—249. DOI: 10.25683/VOLBI.2019.47.271
10. Тихомиров Н. П., Тихомирова Т. М., Ушмаев О. С. Методы эконометрики и многомерного статистического анализа. М.: Экономика, 2011. 647 с.
11. Dhanachandra N., Mangle K., Chanu Y. J. Image segmentation using K-means clustering algorithm and subtractive clustering algorithm // *Procedia Computer Science*. 2015. Vol. 54. Pp. 764—771.
12. Статистический пакет cluster. URL: <https://cran.r-project.org/web/packages/cluster/index.html>
13. Статистический пакет factoextra. URL: <https://cran.r-project.org/web/packages/factoextra/index.html>
14. Li T., Bolic M., Djuric P. M. Resampling methods for particle filtering: classification, implementation, and strategies // *IEEE Signal processing magazine*. 2015. Vol. 32. No. 3. Pp. 70—86.
15. Charrad M., Ghazzali N., Boiteau V., Niknafs A. NbClust: An R Package for Determining the Relevant Number of Clusters in a Data Set // *Journal of Statistical Software*. 2014. No. 61(6). Pp. 1—36.
16. Kaufman L., Rousseeuw P. J. Finding groups in data: an introduction to cluster analysis. John Wiley & Sons, 2009. Vol. 344.
17. Reynolds D. Gaussian mixture models // *Encyclopedia of biometrics*. 2015. Pp. 827—832.
18. Статистический пакет gmm. URL: <https://cran.r-project.org/web/packages/gmm/gmm.pdf>

REFERENCES

1. Hand D. J., Henley W. E. Statistical Classification Methods in Consumer Credit Scoring: A Review. *Journal of Royal Statistical Society*, 1997, vol. 160, pp. 523—541.
2. Hand D. J. Data Mining: New Challenges for Statisticians. *Social Science Computer Review*, 2000, 18(4), pp. 442—449.
3. Altman E. I. et al. Financial distress prediction in an international context: A review and empirical analysis of Altman's Z-score model. *Journal of International Financial Management & Accounting*, 2017, 28(2), pp. 131—171.
4. Edward I. Altman, Robert G. Haldeman and P. Narayanan. ZETATM analysis A new model to identify bankruptcy risk of corporations. *Journal of Banking & Finance*, 1977, 1(1), pp. 29—54.
5. Biryukov A. N. Development of indicators of the author's model in the methodology for assessing the threat of bankruptcy of an enterprise. *Modern research and development*, 2018, pp. 55—65. (In Russ.).
6. Lepetit L., Strobel F. Bank insolvency risk and Z-score measures: A refinement. *Finance Research Letters*, 2015, vol. 13, pp. 214—224. doi: 10.1016/j.frl.2015.01.001
7. Information Agency Spark. URL: <http://www.spark-interfax.ru/>
8. Chelyshev D. S. Methods of reducing the dimension of space in conditions of fuzzy information. *Advanced science*. Articles IV of the Int. Sci. and Practical Conf.
9. Chelyshev D. S. Modelling of Russian banks probability of default. *Business. Education. Law*, 2019, no. 2, pp. 245—249. (In Russ.). DOI: 10.25683/VOLBI.2019.47.271

10. Tihomirov N. P., Tihomirova T. M., Ushmaev O. S. Methods of econometrics and multidimensional statistical analysis. *Economics*, 2011, 647 p. (In Russ.).
11. Dhanachandra N., Manglem K., Chanu Y. J. Image segmentation using K-means clustering algorithm and subtractive clustering algorithm. *Procedia Computer Science*, 2015, vol. 54, pp. 764—771.
12. R package cluster. URL: <https://cran.r-project.org/web/packages/cluster/index.html>.
13. R package factoextra. URL: <https://cran.r-project.org/web/packages/factoextra/index.html>.
14. Li T., Bolic M., Djuric P. M. Resampling methods for particle filtering: classification, implementation, and strategies. *IEEE Signal processing magazine*, 2015, 32(3), pp. 70—86.
15. Malika Charrad, Nadia Ghazzali, Veronique Boiteau, Azam Niknafs. NbClust: An R Package for Determining the Relevant Number of Clusters in a Data Set. *Journal of Statistical Software*, 2014, no. 61(6), pp. 1—36.
16. Kaufman L., Rousseeuw P. J. Finding groups in data: an introduction to cluster analysis. John Wiley & Sons, 2009. Vol. 344.
17. Reynolds D. Gaussian mixture models. *Encyclopedia of biometrics*, 2015. Pp. 827—832.
18. R package gmm. URL: <https://cran.r-project.org/web/packages/gmm/gmm.pdf>

Как цитировать статью: Чельшев Д. С. Классификация российских банков на основе внутренних показателей отчетности // Бизнес. Образование. Право. 2019. № 4 (49). С. 296–303. DOI: 10.25683/VOLBI.2019.49.429.

For citation: Chelyshev D. S. Russian banks classification based on the internal indicators of reporting. *Business. Education. Law*, 2019, no. 4, pp. 296–303. DOI: 10.25683/VOLBI.2019.49.429.

УДК 658.5
ББК 65.291.8

DOI: 10.25683/VOLBI.2019.49.446

Chuvaev Alexey Vladimirovich,
Associate Professor of the Department of Management,
Novosibirsk State Technical University,
Novosibirsk, Russian Federation,
e-mail: chuvaev@corp.nstu.ru

Чуваев Алексей Владимирович,
доцент кафедры менеджмента,
Новосибирский государственный технический университет,
г. Новосибирск, Российская Федерация,
e-mail: chuvaev@corp.nstu.ru

Работа выполнена при финансовой поддержке Новосибирского государственного технического университета (проект С19-20 «Организационные инструменты и механизм реализации бережливого производства: оценка эффективности»)

The work was financially supported by Novosibirsk state technical university (project C19-20 Organizational tools and mechanisms of implementation of the lean production: effectiveness assessment)

МОДЕЛЬ ПРИНЯТИЯ РЕШЕНИЙ В УПРАВЛЕНИИ ПРОИЗВОДСТВЕННЫМИ ПРОЦЕССАМИ

DECISION MAKING MODEL IN MANUFACTURING PROCESSES MANAGEMENT

08.00.05 — Экономика и управление народным хозяйством
08.00.05 — Economics and management of national economy

В статье рассматривается проблема низкой производительности труда промышленных предприятий Российской Федерации. Известно, что производительность труда в России на одного занятого по сравнению со странами G7 отстает в 2010-е гг. почти в 2 раза, и разрыв этот увеличивается. При этом статистика демонстрирует острый дефицит инвестиций в основной капитал, ярко проиллюстрирована необходимость поиска организационных мер, которые позволят получить значительный эффект при существенно более низких инвестиционных вложениях. Главная гипотеза исследования: российские промышленные предприятия, как правило, имеют массу резервов для повышения производительности труда, которого можно достичь за счет рационализации управления производственными процессами собственными силами без привлечения значительных инвестиций. Отправной точкой исследования явилось разделение всего комплекса анализируемых различными авторами проблем на собственно проблемы и их симптоматику, а также их классификация. Основная часть исследования посвящена разработке модели принятия решений по управлению производственными процессами. Модель

представлена декомпозицией и алгоритмом работ, она отличается комплексом процедур и методов выявления и анализа проблем, диагностики производственных процессов, постановки приоритетных задач, оптимизации процессов на основе математической формализации и применения организационных, программных и экспертных методов и инструментов. Разработанная модель была апробирована на ряде отечественных предприятий Новосибирской и Томской областей и показала свою состоятельность. Практика свидетельствует о том, что ее использование позволяет выявить существенные резервы предприятий, минимизировать затраты и повысить эффективность управления производством без существенных инвестиционных вложений.

The article considers the issue of low labor productivity of industrial enterprises of Russian Federation. It is known that labor productivity per employed in Russia is almost 2 times behind compared to the G-7 countries in 2010s, and this gap is widening. Given that statistics show an acute shortage of fixed assets investments, the need to search for organizational activities that will