

DOI: 10.12731/2070-7568-2024-13-1-235

УДК 330.44



Научная статья | Финансы

ИЕРАРХИЧЕСКАЯ КЛАСТЕРИЗАЦИЯ И DEEP LEARNING МОДЕЛЬ “RANDOM FOREST” УСТОЙЧИВОСТИ БАНКОВ В УСЛОВИЯХ РИСКА

*Н.И. Ломакин, Т.И. Кузьмина, М.С. Марамыгин, С.Н. Дергачева,
Ю.Т. Цебекова, Канчана Вималаратхне, И.Н. Ломакин*

Исследованы отдельные теоретические аспекты устойчивости российских банков в условиях риска. Актуальность обусловлена тем, что в условиях рыночной неопределенности и риска все чаще применяются подходы для обеспечения устойчивости банков с использованием искусственного интеллекта. Цель состоит в том, чтобы выявить закономерности между признаками Активы и ROA (Return on Assets) показателем рентабельности активов, и получить прогнозное значение чистой прибыли Сбербанка.

Результатом исследования явилась иерархическая кластеризация, а также сформированная Deep Learning модель “Random Forest”, которая рассчитала прогнозное значение чистой прибыли Сбербанка.

Новизна заключается в том, что в работе выдвинута и доказана гипотеза, что с помощью Deep Learning модели “Random Forest” может быть получен прогноз величины чистой прибыли коммерческих банков, что предопределяет устойчивость и динамику их развития.

Выводы по результатам исследования сводятся к тому, разработана Deep Learning модель “Random Forest” для прогноза величины чистой прибыли, которая для Сбера на 2023 год составила 38631 млрд. рублей, что совпало с его фактическим значением. Область применения полученных результатов – коммерческие банки.

Ключевые слова: Machine Learning; Deep Learning модель; иерархическая кластеризация

Для цитирования. Ломакин Н.И., Кузьмина Т.И., Марамыгин М.С., Дергачева С.Н., Цебекова Ю.Т., Вималаратхне Канчана, Ломакин И.Н. Иерархическая кластеризация и Deep Learning модель “Random Forest” устойчивости банков в условиях риска // Наука Красноярья: экономический журнал. 2024. Т. 13, №1. С. 88-102. DOI: 10.12731/2070-7568-2024-13-1-235

Original article | Finance

HIERARCHICAL CLUSTERIZATION AND DEEP LEARNING MODEL RANDOM FOREST OF BANKS' STABILITY UNDER RISK CONDITIONS

*N.I. Lomakin, T.I. Kuzmina, M.S. Maramygin, S.N. Dergacheva,
Yu. T. Tsebekova, Kanchana Vimalarathne, I.N. Lomakin*

Certain theoretical aspects of the stability of Russian banks under risk conditions have been studied. The relevance is due to the fact that in conditions of market uncertainty and risk, approaches to ensure the stability of banks using artificial intelligence are increasingly being used. The goal is to identify patterns between the characteristics of Assets and ROA (Return on Assets), an indicator of return on assets, and obtain a forecast value of Sberbank's net profit.

The result of the study was hierarchical clustering, as well as the generated Deep Learning model Random Forest, which calculated the predicted value of the Sberbank's net profit.

The novelty lies in the fact that the work puts forward and proves the hypothesis that using the Random Forest Deep learning model, a forecast of the net profit of commercial banks can be obtained, which predetermines the stability and dynamics of their development. The conclusions from the study boil down to the fact that a Deep Learning model Random Forest was developed to forecast the amount of net profit, which for Sberbank for 2023 amounted to 38,631 billion rubles, which coincided with its actual value. The area of application of the results obtained is commercial banks.

Keywords: *Machine Learning; Deep Learning model; Hierarchical Clustering*

For citation. *Lomakin N.I., Kuzmina T.I., Maramygin M.S., Dergacheva S.N., Tsebekova Yu.T., Vimalarathne Kanchana, Lomakin I.N. Hierarchical Clusterization and Deep Learning Model Random Forest of Banks' Stability under Risk Conditions. Krasnoyarsk Science: Economic Journal, 2024, vol. 13, no. 1, pp. 88-102. DOI: 10.12731/2070-7568-2024-13-1-235*

Важное значение в современных условиях имеет устойчивое развитие отечественной банковской системы, что предполагает обеспечение баланса между альтернативными направлениями развития: ее стабильностью и ее ростом. Исследование теоретических основ оценки устойчивости развития банковской системы России и его прогнозирования в условиях рыночной

неопределенности и риска с применением подходов интеллектуального моделирования имеет важное значение.

Цель исследования

Цель исследования заключается в том, чтобы сформировать подходы, которые позволяют выявить имеющиеся закономерности, в частности, величина признака X_6 – ROA увеличивается у банков по мере роста параметра «Активы», и сформировать прогноз параметра «Чистая прибыль» банковской системы на основе искусственного интеллекта. Актуальность исследования обусловлена тем, что для обеспечения устойчивого развития банковского сектора и сферы финансов все чаще применяются системы искусственного интеллекта (далее ИИ) [10]. Новизна заключается в том, что авторами предложены подходы, которые позволяют выявить имеющиеся закономерности и сформировать прогноз параметра «Чистая прибыль» банковской системы на основе искусственного интеллекта. В работе выдвинута и доказана гипотеза, что с помощью Deep Learning модели «Random forest» может быть получен прогноз величины чистой прибыли коммерческих банков, что предопределяет устойчивость и динамику их развития.

Практическая значимость состоит в том, что результаты, полученные в ходе исследования могут быть использованы для поддержки принятия стратегических решений, связанных с формированием и распределением чистой прибыли. В ходе исследования была выдвинута и доказана гипотеза, что с помощью DL-модели «Случайный лес» можно получить прогнозное значение чистой прибыли банков.

Использование ИИ-систем для обеспечения устойчивости коммерческих банков находится в центре внимания отечественных и зарубежных ученых. Например, П.С. Урлапов и М.С. Марамыгин исследовали современные тенденции развития банковского сектора Российской Федерации в условиях экономической неопределенности. Н.И. Ломакиным и его соавторами была предложена когнитивная модель финансовой устойчивости отечественной экономики на основе ИИ [17, с. 1588-1597]. Им же была разработана модель прогнозирования устойчивости банковской системы Российской Федерации на основе модели «Случайного леса» [7, с. 78-100]. Кроме того, вопросам финансовой устойчивости коммерческих банков посвящены исследования таких ученых, как: М.А. Котляров [6, с. 6-9], С. Хорошев [12, с. 53-56], И.С. Велиева, О.Н. Комардина, П.А. Самиев [2, с. 38-45]. Решению проблемы устойчивости и управления риском банковской деятельности посвящены исследования многих ученых, в том

числе, С.Н. Комогорцева [5, с. 37-40], И.П. Вишнякова [3, с. 46-53], а также О.Н. Асаевой [1, с. 111-114]. Н.Н. Мокеева, рассматривая механизмы системы страхования вкладов, предложила эффективные подходы, направленные на обеспечение устойчивости банковской системы [9, с. 152-158]. С.В. Дзюбан исследовал систему мониторинга финансовой устойчивости банковского сектора. Рассмотренные подходы, к сожалению, не опирались на преимущества ИИ, поэтому авторами было проведено настоящее исследование касательно финансовой устойчивости банковской системы в основе которого лежало применение ИИ.

Практика показывает, что использование систем искусственного интеллекта позволяет решать широкий спектр задач, в том числе, от выявления закономерностей между факторами, до оценки финансовой устойчивости и прогнозирования чистой прибыли.

В процессе формирования современной системы, которая призвана способствовать развитию банковского сектора, Христос В. Горцос отмечает, что важно использовать основы теории банковского регулирования [15, с. 161-198]. Анджан Тако пытался выяснить путь для достижения баланса между финансовой стабильностью и экономическим ростом [13, с. 54-56].

Значительное количество ученых посвятили свои публикации изучению проблем, связанных с использованием когнитивных моделей, искусственного интеллекта, а также их взаимодействием, например, Уэймонд Роджерс и его коллеги, сформировали парадигму передачи знаний умных сетей, которая поддерживается экспертами [18]. Хэнсюй Линь с коллегами предложили модель глубокого обучения для выявления скрытых факторов риска [16].

Методы и методология проведения работы

При проведении исследований авторами использовались преимущества монографического, аналитического методов, применялась AI-система - модель машинного обучения «Дерево решений». Расчеты выполнялись в таблицах XL, облачном сервисе Google Collab [7]. Как показывают исследования, в современных условиях отмечается широкомасштабное развитие процессов цифровизации, в частности, М.А. Котляров при изучении динамики рыночной капитализации, как инструмента повышения устойчивости российских банков, отмечает среди факторов растущую цифровизацию бизнес-процессов в банках, в частности, широкое применение Deep Learning моделей в целях прогнозирования [6].

Метод случайного леса представляет собой эффективный алгоритм ма-

шинного обучения, предложенный Брейманом Лео, суть которого заключается в использовании ансамбля деревьев решений [14, с. 5-32]. Среди перспективных направлений использования глубоких нейронных сетей можно выделить их использование в банковской и инвестиционной сфере [8, с. 7-21].

В работе были применены такие методы, как монографический, аналитический, DL-модель «Случайный лес» на сервисе Colab с использованием языка Python и библиотек pandas, GridSearchCV, sklearn и других. На первом этапе исследования была сформирована нейросетевая модель иерархической кластеризации, Нейросеть была сформирована алгоритмом «обучения без учителя». На втором этапе была разработана модель машинного обучения DL-модель «Случайный лес», которая позволила получить прогнозное значение чистой прибыли коммерческих банков. Алгоритм выбрал лучшее дерево DL-модели, которое имело минимальное значение ошибки (MAE).

Результаты

Сформирована DL-модель «Случайный лес» для получения прогноза величины чистой прибыли коммерческими банками. Банковская система, выступает важнейшим элементом финансовой системы государства. Распределение активов среди банков также неравномерно, причем прирост прибыли (в %) отличается у разных банков (таблица 1).

Таблица 1.

Фрагмент исходных данных по Топ 31 банкам в 2022 г.

	Активы, млрд. руб.	Чистая прибыль, млрд. руб.	Прирост чистой прибыли, %	VaR млрд. руб.	Сигма (риск)
1. ПАО Сбербанк	38631	1237	4,1	30,2	17,3
2. ВТБ	26188	241	0,4	2,6	17,0
3. Газпромбанк	15296	178	0,8	5,8	17,3
4. Альфа-Банк	8411	99	1,8	12,8	17,6
5. Национальный Клиринговый центр	7527	36	-0,1	-0,9	17,9
...
29. ОТП Банк	350	21,7	7,3	53,7	31,5
30. Банк ТКБ	327	2,6	7,6	55,4	39,2
31. Росдорбанк	24	0,303	0,0	0,0	0,0

Источник: [17]

По данным Центробанка РФ по итогам 2022 г. из 134800 млрд руб. на Топ 30 банков приходится 98,5% активов. В пятерку лидеров вошли: ПАО Сбербанк - 44,5 (с приростом чистой прибыли 4,1%), Банк ВТБ (ПАО)-26188 (0,4%), Газпромбанк - 15296 (0,8%), АО АЛЬФА-БАНК - 8411 (1,8%), Национальный Клиринговый центр - 7527 (-0,1%) при среднем значении стоимости активов по выборке 4284,9 млрд. руб. Важное значение имеет оценка риска изменения активов в выбранной совокупности банков. Расчеты VaR-модели были проведены на сайте. Гистограмма распределения представлена ниже (рисунок 1).

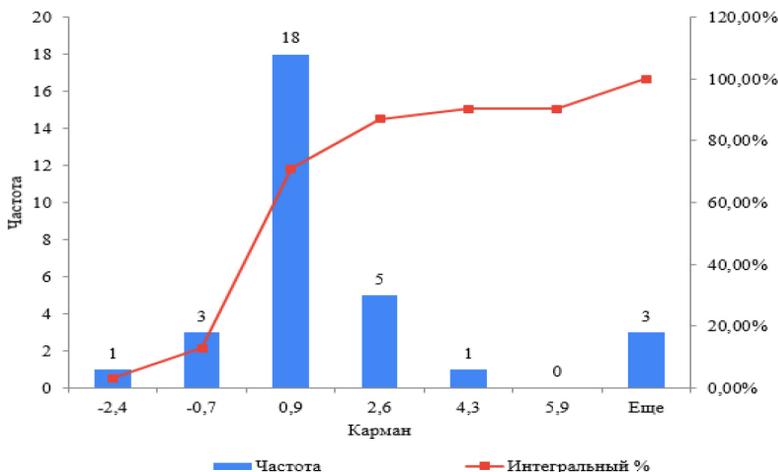


Рис. 1. Гистограмма распределения VaR-модели
 Источник: [авторская разработка]

Для удобства были введены обозначения полей таблицы датасета DL-модели, исходные параметры DL-модели представен ниже (таблица 2).

В модель включены следующие параметры (поля): X1 – Активы банков, млрд. руб.; X2 – Прирост активов за год, %; X3 – Чистая прибыль, млрд. руб.; X4 – Прирост чистой прибыли, %; X5 - Собств. Капитал, млрд руб.; X6 – ROA; X7 – ROE; X8 - Кредитный портфель, млрд. руб.; X9 - Прирост кредитного портфеля, %; X10 - Просроченная задолженность, млрд. руб.; X11 - Доля просроченных кредитов, %; X12 - Н1(10%); X13 - Н2(>15); X14 - Н3(>50). Y – Чистая прибыль, млрд. руб. Для исследования закономерностей в массиве данных (датасете) целесообразно использовать современные методы на основе искусственного интеллекта.

Таблица 2.

Датасет для использования в цифровых моделях (фрагмент)

Банки	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X14	Y
Сбер	38,6	-0,4	1237	7,81	5157	3,2	23,9	36,5	0,91	155	0,42	13,0	64,9	1237
ВТБ	26,2	34,4	241	30,1	1781	0,9	13,5	15,8	0,33	112	0,71	9,91	63,3	241
Газп	15,3	77,4	178	-25	1227	1,2	14,5	10,9	6	24	0,22	10,4	92,7	178
Альф	8,4	46,8	99	5,87	837	1,2	11,8	5,7	2,7	23	0,4	11,9	95,4	99
НКЦ	7,5	23,6	36	16,1	111	0,4	32,4	1,8	7,5	0,38	0,02	22,4	116	36
МКБ	4,9	42,7	41	-4,4	380	0,8	10,7	3,1	-1,3	29	0,93	12,0	90,8	41
Россе	4,6	9,56	21	-31	599	0,4	3,51	3,4	3,99	25	0,73	15,2	194	21
Откр	3,2	-2,1	59	23,4	380	1,8	15,5	1,7	-10	14	0,81	13,9	27,0	59
Совк	3,0	44,9	97	2,98	332	3,2	29,2	1,8	1,69	17	0,9	12	99,2	97
Дом.	2,3	154	31	0,73	262	1,3	11,8	1,5	1,71	7	0,44	13,1	69,6	31

Источник: [17]

Иерархическая кластеризация

Иерархическая кластеризация, представляет собой алгоритм, который строит иерархию кластеров. Он начинает работу с того, что каждому экземпляру данных сопоставляется свой собственный кластер. Затем два ближайших кластера объединяются в один и так далее, пока не будет образован один общий кластер. При этом анализируемые параметры «нормализуются» - приводятся к единому масштабу. Дендрограмма кластеризации представлена на рисунке 2.

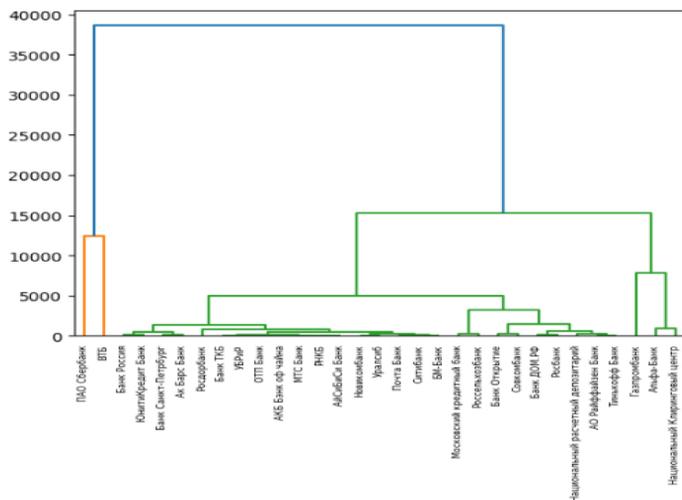


Рис. 2. Дендрограмма иерархической кластеризации по ROA

Источник: [авторская разработка]

Представляет интерес использование Deep Learning модели «Random Forest».

Нейросеть DL-модель «Случайный лес»

Нейросеть Deep Learning модель «Random Forest», которая была сформирована чтобы получить прогноз чистой прибыли коммерческих банков. Исходные данные и экранные формы модели представлены на Google диске [17]. Датасет для Deep Learning модели «Random Forest» представлен в таблице 3.

Таблица 3.

Датасет для Deep Learning модели «Random Forest» в Colab (фрагмент)

	X1	X2	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	target
Сбер	38631	-0,47	7,81	5157	3,2	23,99	36565	0,91	155	0,4	13,01	64,92	86,28	1237
ВТБ	26188	34,40	30,16	1781	0,92	13,63	15789	0,33	112	0,71	9,91	63,33	110	241
ГПБ	15296	77,44	-25,71	1227	1,16	14,51	10862	6,00	24	0,22	10,48	92,79	69,74	178

Источник: [авторская разработка]

Формирование DL-модели предполагает использование библиотек pandas, matplotlib.pyplot, sklearn, LinearRegression, RandomForestRegressor.

Прогнозные значения были получены при следующих гиперпараметрах: 'criterion': 'absolute_error', 'max_depth': 10, 'n_estimators': 5. То есть 5 эстиматоров (деревьев), при максимальной глубине дерева 10 уровней. Уравнение регрессии, описывающее зависимость между факториальными признаками, включенными в модель, и результативным признаком, представлено ниже:

$$\begin{aligned}
 Y = & -18.6 - 0.007 * X1 + 0.05 * X2 + 0.002 * X3 + 0.36 * X4 - 9.71 * X5 + \\
 & + 1.28 * X6 - 0.005 * X7 + 0.12 * X8 - 1.17 * X9 + 0.37 * X10 - \\
 & - 0.24 * X11 - 0.48 * X12 + 0.36 * X14,
 \end{aligned}
 \tag{3}$$

Расчеты показали, что средняя абсолютная ошибка полученного прогноза составляет 421,142. Прогнозное значение чистой прибыли было получено путем подстановки в модель входных параметров с использованием sample-вектора, при этом прогнозная величина чистой прибыли Сбера на 2023 год составила 38631 млрд. рублей, что совпало с фактическим значением.

Обсуждение

Перспективы дальнейших исследований видятся исходя из результатов, полученных в ходе проведения настоящего исследования, в том, чтобы повы-

сдать точность прогнозирования, для чего целесообразно сравнить величины ошибок прогнозов, получаемых деревом решений и Deep Learning моделью «Random Forest». Полученные результаты позволили выявить определенные закономерности в рассматриваемых данных. В частности, иерархическая кластеризация способствовала выявлению зависимости между признаками Активы, млрд. руб. и ROA. Важность проведенного исследования с теоретической точки зрения состоит в том, что использованный метод «иерархическая кластеризация», представляющий собой ИИ «с обучением без учителя» использует неразмеченные данные датасета, группирует данные определенным образом, по алгоритму, заложенному в модель. При этом банки объединяются в кластеры – группы, которые характеризуются определенной однородностью. Так, например, на уровне 15 000 млрд. руб. вся выборка была разделена программой на два кластера, причем, в первый вошли Сбербанк и ВТБ, а во второй – все остальные банки. Если в ходе исследования потребуется рассмотреть «рентабельность активов (ROA)» при кластеризации по размеру активов банков на уровне 10000 млрд. рублей, то на основе дендрограммы можно выявить уже четыре кластера: 1) Сбербанк; 2) ВТБ; 3) Газпромбанк, Альфа-Банк и Национальный клиринговый центр; 4) Все остальные банки. И так далее, что дает возможность судить о финансовых результатах деятельности банков, при различной степени детализации признака – «Активы». В практическом плане это важно с той точки зрения, что масштабируя интервал параметра «Активы» аналитик может получить необходимые данные по тем, или иным группам банков, включенных в кластеры, объединяющие однородные банки по признаку «ROA», например, при принятии решения с какими банками работать на рынке межбанковского кредитования. Метод иерархической кластеризации известен, он стоит в одном ряду с методом k-средних, методом «ближайших соседей», однако в банковской сфере, видимо, применяется редко, в связи с тем, что требует определенного уровня знаний программирования и цифровизации аналитических процессов, а так же достаточных производственных мощностей компьютера для обработки. Тем не менее, на облачном сервисе Collab он прекрасно реализуется, что сулит хорошие перспективы его применения для поиска закономерностей при анализе больших данных.

Нейросетью DL-модель «Случайный лес» был успешно сформирован прогноз чистой прибыли банков, вошедших в Топ 30 на основе динамики 14 параметров, включенных в датасет модели, что позволяет прогноз прибыли для любого банка и судить об устойчивом развитии, например, Сбербанка в перспективе.

Выводы

Иерархическая кластеризация способствовала выявлению зависимости между признаками Активы, млрд. руб. и ROA. Разработана DL-модель «Случайный лес» для прогноза величины чистой прибыли. Прогнозная величина чистой прибыли Сбербанка на 2023 год составила 38631 млрд. рублей, что совпало с фактическим значением.

Список литературы

1. Асаева О.Н. Развитие и совершенствование системы мер обеспечения устойчивости банковской системы Российской Федерации // Молодой ученый. 2018. № 50 (236). С. 111-114.
2. Велиева И.С., Комардина О.Н., Самиев П.А. Финансовая устойчивость российских банков // Аудитор. 2008. № 3 (157). С. 38-45.
3. Вишняков И.П. Методология анализа устойчивости региональной банковской системы в императиве устойчивости банковской системы в целом // Финансовые исследования. 2017. № 3 (56). С. 46-53.
4. Дзюбан С.В. Система мониторинга финансовой устойчивости банковского сектора // Взаимодействие реального и финансового секторов в трансформационной экономике. Материалы Международной научной конференции. Оренбург, 2008. С. 215-217.
5. Комогорцев С.Н. Приемы анализа и методики оценки финансовой устойчивости банков в современной российской и мировой практике // Мир современной науки. 2012. № 3 (12). С. 37-40.
6. Котляров М.А. Рыночная капитализация как инструмент повышения устойчивости российских банков // Финансы и кредит. 2006. № 28 (232). С. 6-9.
7. Ломакин Н.И., Юрова О.В., Кособокова Е.В. Модель Random Forest на основе Big Data для прогнозирования устойчивости банковской системы Российской Федерации // Наука Красноярья. 2023. Т. 12, № 1-1. С. 78-100. <https://doi.org/10.12731/2070-7568-2023-12-1-78-100>
8. Ломакин Н.И., Юрова О.В., Терехов Т.В., Шабанов Н.Т. Разработка робо-эдвайзера на основе искусственного интеллекта по методу «случайный лес» как фактор повышения инвестиционной активности населения // π -Economy. 2023. Т. 16, № 3. С. 7-21. <https://doi.org/10.18721/JE.16301>
9. Мокеева Н.Н. Финансовые механизмы системы страхования вкладов в рамках обеспечения устойчивости банковской системы России и инновационного развития // Урал - драйвер неоиндустриального и инновационного развития России. Материалы II Уральского экономического форума, в 2 т. Екатеринбург, 2020. С. 152-158.

10. Сомов А.Г., Олейник Д.А., Калинина О.В. Применение гибридных систем на основе искусственного интеллекта для улучшения процесса принятия управленческих решений // Современная наука: актуальные проблемы теории и практики. Серия: Экономика и право. 2023. № 9. С. 74-78. <https://doi.org/10.37882/2223-2974.2023.09>.
11. Урлапов П.С., Марамыгин М.С. Современные тенденции развития банковского сектора Российской Федерации в условиях экономической неопределенности // Современные тенденции развития финансово-банковского сектора в условиях экономической неопределенности. Сборник трудов международной научно-практической конференции. Нур-Султан, 2022. С. 202-206.
12. Хорошев С. Моделирование переломных ситуаций в российской экономике и устойчивость банков // Банковское дело. 2008. № 4. С. 53-56.
13. Anjan V. Thakor The purpose of banking: transforming banking for stability and economic growth. Book Review. 2020. Volume 56. P. 54–56. URL: <https://link.springer.com/article/10.1057/s11369-020-00196-y> (accessed 08.03.2024)
14. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45. P. 5-32. <https://doi.org/10.1023/A:1010933404324>
15. Christos V.G. The European Banking Regulation Handbook, Volume I. Theory of Banking Regulation, International Standards // Evolution and Institutional Aspects of European Banking Law. 2023. P. 161-198. URL: <https://link.springer.com/book/10.1007/978-3-031-32859-6> (accessed 08.03.2024)
16. Hengxu L., Dong Z., Weiqing L., Jiang B. Deep Risk Model: A Deep Learning Solution for Mining Latent Risk Factors to Improve Covariance Matrix Estimation // In 2nd ACM International Conference on AI in Finance (ICAIF'21), November 3–5, 2021, Virtual Event, USA. ACM, New York, NY, USA, 8 p. <https://doi.org/10.1145/3490354.3494377>
17. Lomakin N., Maramygin M., Kataev A., Kraschenko S., Yurova O., Lomakin I. Cognitive model of financial stability of the domestic economy based on artificial intelligence in conditions of uncertainty and risk // International Journal of Technology. 2022. T. 13. № 7. P. 1588-1597.
18. Rodgers W., Cardenas J.A., Gemoets L.A., Sarfi R.J. A smart grids knowledge transfer paradigm supported by experts' throughput modeling artificial intelligence algorithmic processes // Technological Forecasting and Social Change. 2023. Vol. 190, 122373. <https://doi.org/10.1016/j.techfore.2023.122373>

References

1. Asaeva O.N. Development and improvement of the system of measures to ensure the stability of the banking system of the Russian Federation. *Molodoy uchenyy* [Young scientist], 2018, no. 50 (236), pp. 111-114.

2. Velieva I.S., Komardina O.N., Samiev P.A. Financial stability of Russian banks. *Auditor*, 2008, no. 3 (157), pp. 38-45.
3. Vishnyakov I.P. Methodology for analyzing the sustainability of the regional banking system in the imperative of sustainability of the banking system as a whole. *Finansovye issledovaniya* [Financial Research], 2017, no. 3 (56), pp. 46-53.
4. Dzyuban S.V. System for monitoring the financial stability of the banking sector. *Interaction of the real and financial sectors in the transformation economy. Materials of the International Scientific Conference*. Orenburg, 2008, pp. 215-217.
5. Komogortsev S.N. Techniques of analysis and methods for assessing the financial stability of banks in modern Russian and world practice. *Mir sovremennoy nauki* [World of modern science], 2012, no. 3 (12), pp. 37-40.
6. Kotlyarov M.A. Market capitalization as a tool for increasing the stability of Russian banks. *Finansy i kredit* [Finance and Credit], 2006, no. 28 (232), pp. 6-9.
7. Lomakin N.I., Yurova O.V., Kosobkova E.V. Random Forest model based on Big Data for predicting the stability of the banking system of the Russian Federation. *Nauka Krasnoyarska* [Krasnoyarsk Science], 2023, vol. 12, no. 1-1, pp. 78-100. <https://doi.org/10.12731/2070-7568-2023-12-1-78-100>
8. Lomakin N.I., Yurova O.V., Terekhov T.V., Shabanov N.T. Development of a robo-advisor based on artificial intelligence using the “random forest” method as a factor in increasing the investment activity of the population. *π-Economy*, 2023, vol. 16, no. 3, pp. 7-21. <https://doi.org/10.18721/JE.16301>
9. Mokeeva N.N. Financial mechanisms of the deposit insurance system within the framework of ensuring the sustainability of the Russian banking system and innovative development. *Ural - driver of neo-industrial and innovative development of Russia. Materials of the II Ural Economic Forum*, 2 volumes. Ekaterinburg, 2020, pp. 152-158.
10. Somov A.G., Oleinik D.A., Kalinina O.V. Application of hybrid systems based on artificial intelligence to improve the process of making management decisions. *Sovremennaya nauka: aktual'nye problemy teorii i praktiki. Seriya: Ekonomika i pravo* [Modern science: current problems of theory and practice. Series: Economics and law], 2023, no. 9, pp. 74-78. <https://doi.org/10.37882/2223-2974.2023.09.35>
11. Urlapov P.S., Maramygin M.S. Modern trends in the development of the banking sector of the Russian Federation in conditions of economic uncertainty. *Modern trends in the development of the financial and banking sector in conditions of economic uncertainty. Collection of proceedings of the international scientific and practical conference*. Nur-Sultan, 2022, pp. 202-206.
12. Khoroshev S. Modeling turning points in the Russian economy and the stability of banks. *Bankovskoe delo* [Banking], 2008, no. 4, pp. 53-56.

13. Anjan V. *Thakor The purpose of banking: transforming banking for stability and economic growth*. Book Review. 2020. Volume 56. P. 54–56. URL: <https://link.springer.com/article/10.1057/s11369-020-00196-y> (accessed 08.03.2024)
14. Breiman L. Random Forests. *Machine Learning*, 2001, vol. 45, pp. 5-32. <https://doi.org/10.1023/A:1010933404324>
15. Christos V.G. The European Banking Regulation Handbook, Volume I. Theory of Banking Regulation, International Standards. *Evolution and Institutional Aspects of European Banking Law*, 2023, pp. 161-198. URL: <https://link.springer.com/book/10.1007/978-3-031-32859-6> (accessed 08.03.2024)
16. Hengxu L., Dong Z., Weiqing L., Jiang B. Deep Risk Model: A Deep Learning Solution for Mining Latent Risk Factors to Improve Covariance Matrix Estimation. In *2nd ACM International Conference on AI in Finance (ICAIF'21)*, November 3–5, 2021, Virtual Event, USA. ACM, New York, NY, USA, 8 p. <https://doi.org/10.1145/3490354.3494377>
17. Lomakin N., Maramygin M., Kataev A., Kraschenko S., Yurova O., Lomakin I. Cognitive model of financial stability of the domestic economy based on artificial intelligence in conditions of uncertainty and risk. *International Journal of Technology*, 2022, vol. 13, no. 7, pp. 1588-1597.
18. Rodgers W., Cardenas J.A., Gemoets L.A., Sarfi R.J. A smart grids knowledge transfer paradigm supported by experts' throughput modeling artificial intelligence algorithmic processes. *Technological Forecasting and Social Change*, 2023, vol. 190, 122373. <https://doi.org/10.1016/j.techfore.2023.122373>

ДААННЫЕ ОБ АВТОРАХ

Ломакин Николай Иванович, к.э.н., доцент

*Волгоградский государственный технический университет
просп. В.И. Ленина, 28, г. Волгоград, 400005, Российская Федерация
tel9033176642@yahoo.com*

Кузьмина Татьяна Ивановна, д.э.н., профессор

*Российский экономический университет им. Г.В. Плеханова
Стремянный переулок, 36, г. Москва, 115054, Российская Федерация
tutor07@list.ru*

Марамыгин Максим Сергеевич, д.э.н., профессор, директор института финансов и права, профессор кафедры финансов, денежного обращения и кредита

*Уральский государственный экономический университет
ул. 8 Марта, 62, г. Екатеринбург, 620144, Российская Федерация
taram_m_s@mail.ru*

Дергачева Светлана Николаевна, к.э.н., доцент

*Российский экономический университет имени Г.В. Плеханова, Волгоградский филиал
ул. Волгодонская, 11, г. Волгоград, 400066, Российская Федерация
avangard34@bk.ru*

Цебекова Юлия Тюрбеевна, бакалавр

*Волгоградский государственный технический университет
просп. В.И. Ленина, 28, г. Волгоград, 400005, Российская Федерация
cebekovaulia@gmail.com*

Вималаратхне Канчана, магистрант

*Волгоградский государственный технический университет
просп. В.И. Ленина, 28, г. Волгоград, 400005, Российская Федерация
kanchana_wimalarathna@yahoo.com*

Ломакин Иван Николаевич, магистрант кафедры Системы автоматизированного проектирования и поискового конструирования
*Волгоградский государственный технический университет
просп. В.И. Ленина, 28, г. Волгоград, 400005, Российская Федерация
ivan.grom0boy@yandex.ru*

DATA ABOUT THE AUTHORS

Nikolay I. Lomakin, Candidate of Economic Sciences, Associate Professor

*Volgograd State Technical University
28, Lenin Ave., Volgograd, 400005, Russian Federation
tel9033176642@yahoo.com
ORCID: <https://orcid.org/0000-0001-6597-7195>*

Tatyana I. Kuzmina, Doctor of Economics, Professor

*Russian Economic University
36, Stremyanny Lane, Moscow, 115054, Russian Federation
tutor07@list.ru
ORCID: <https://orcid.org/0000-0002-1757-5201>*

Maxim S. Maramygin, Doctor of Economics, Professor, Director of the Institute of Finance and Law, Professor of the Department of Finance, Monetary Circulation and Credit
Ural State Economic University
62, 8 Marta Str., Ekaterinburg, 620144, Russian Federation
maram_m_s@mail.ru
ORCID: <https://orcid.org/0000-0003-3416-775X>

Svetlana N. Dergacheva, Candidate of Economic Sciences, Associate Professor
Russian Economic University named after G.V. Plekhanov, Volgograd branch
11, Volgodonskaya Str., Volgograd, 400066, Russian Federation
avangard34@bk.ru

Yulia T. Tsebekova, bachelor
Volgograd State Technical University
28, Lenin Ave., Volgograd, 400005, Russian Federation
cebekovaulia@gmail.com
ORCID: <https://orcid.org/0009-0000-6314-4237>

Kanchana Vimalarathne, master's student
Volgograd State Technical University
28, Lenin Ave., Volgograd, 400005, Russian Federation
kanchana_wimalarathna@yahoo.com
ORCID: <https://orcid.org/0000-0002-0853-7211>

Ivan N. Lomakin, master's student of the Department of Computer-Aided Design and Search Design
Volgograd State Technical University
28, Lenin Ave., Volgograd, 400005, Russian Federation
ivan.grom0boy@yandex.ru
ORCID: <https://orcid.org/0000-0001-7392-1554>

Поступила 06.03.2024
После рецензирования 18.03.2024
Принята 24.03.2024

Received 06.03.2024
Revised 18.03.2024
Accepted 24.03.2024