

УДК 659.1

МОДЕЛЬ ГЛУБОКОГО ОБУЧЕНИЯ «RANDOM FOREST REGRESSION» ДЛЯ ПРОГНОЗИРОВАНИЯ УСТОЙЧИВОСТИ БАНКОВСКОЙ СИСТЕМЫ**¹Н.И. Ломакин, ²М.С. Марамыгин, ³Т.И. Кузьмина, ⁴Н.Н. Бескоровайная, ⁴С.Н. Дергачева, ⁴С.А. Карабинцева, ¹И.Н. Ломакин**¹ Волгоградский государственный технический университет, Волгоград, email: tel9033176642@yahoo.com² Уральский государственный экономический университет, Екатеринбург, email: maram_m_s@mail.ru³ Российский экономический университет им. Г.В. Плеханова, Москва, email: tutor07@list.ru⁴ Волгоградский филиал РЭУ им. Г.В. Плеханова, Волгоград, email: bn700@mail.ru, avangard34@bk.ru, svetlana.karabintzeva@yandex.ru

Аннотация. На фоне широкомасштабного применения искусственного интеллекта во всех отраслях и сферах деятельности, отмечается успешное использование моделей глубокого обучения в банковской сфере для достижения целей устойчивого развития (ЦУР). В этой связи прогнозирование устойчивости банковской системы обуславливает актуальность данного исследования в современных условиях. При этом наиболее эффективным методом прогнозирования все чаще становятся нейросети для формирования прогнозов требуемых параметров в финансовом и банковском секторах. Цель настоящего исследования состоит в том, чтобы сформировать модель глубокого обучения (DL-модель) «Random Forest Regression», которая позволит получить прогнозное значение параметра «Прирост активов, %» и в последующем сравнить его с прогнозом, полученным на основе VaR-модели, в основе которой лежат статистические методы. Научная новизна состоит в том, что предложенный подход позволяет ликвидировать «научный разрыв», представляя собой приращение научного знания в области прогнозирования устойчивого развития банковской системы. В настоящем исследовании выдвинута и доказана гипотеза, что, можно получить прогноз параметра «Прирост активов, %» в целях устойчивого развития банковской системы, используя DL-модель «Random Forest Regression». Практическая значимость обусловлена тем, что результаты исследования могут быть рекомендованы к использованию на практике для обеспечения устойчивого развития коммерческих банков и банковской системы в целом. На основе проведенного исследования были получены следующие результаты. Исследования показали, что наблюдается положительная сильная связь между результативным признаком «target» («Прирост активов, %») и факториальным признаком X_{10} «Частота запроса в Google, %», при этом величина коэффициента составила 0,902. Наблюдается относительно сильная положительная связь у признака X_4 «Доля активов банков в ВВП» 0,396. В итоге нейросеть DL-модель сформировала прогноз прироста активов в 2025 году 6,56%, VaR-модель показала 84,53%, метод экспертных оценок указал на 2,05%.

Ключевые слова: DL-модель, банковская система, обеспечение устойчивого развития, «Случайный лес».

DEEP LEARNING MODEL "RANDOM FOREST REGRESSION" FOR FORECASTING STABILITY OF THE BANKING SYSTEM**¹N.I. Lomakin, ²M.S. Maramygin, ³T.I. Kuzmina, ⁴N.N. Beskorovainaya, ⁴S.N. Dergacheva, ⁴S.A. Karabintseva, ¹I.N. Lomakin**¹ Volgograd State Technical University, Volgograd, email: tel9033176642@yahoo.com² Ural State Economic University, Ekaterinburg, email: maram_m_s@mail.ru³ Russian Economic University named after G.V. Plekhanov, Moscow, email: tutor07@list.ru⁴ Volgograd Branch of REU named after G.V. Plekhanov, Volgograd, email: bn700@mail.ru, avangard34@bk.ru, svetlana.karabintzeva@yandex.ru

Abstract. Against the background of the widespread use of artificial intelligence in all industries and areas of activity, the successful use of deep learning models in the banking sector to achieve sustainable development goals (SDGs) is noted. In this regard, forecasting the sustainability of the banking system determines the relevance of this study in modern conditions. At the same time, neural networks are increasingly becoming the most effective forecasting method for generating forecasts of the required parameters in the financial and banking sectors. The purpose of this study is to form a deep learning model (DL model) "Random Forest Regression" which will allow obtaining the forecast value of the parameter "Asset growth, %" and subsequently compare it with the forecast obtained on the basis of the VaR

model, which is based on statistical methods. Scientific novelty is that the proposed approach allows eliminating the "scientific gap", representing an increase in scientific knowledge in the field of forecasting the sustainable development of the banking system. In this study, we put forward and proved the hypothesis that it is possible to obtain a forecast of the parameter "Asset growth, %" for the purposes of sustainable development of the banking system using the DL-model "Random Forest Regression". The practical significance is due to the fact that the results of the study can be recommended for use in practice to ensure sustainable development of commercial banks and the banking system as a whole. Based on the study, the following results were obtained. The studies have shown that there is a positive strong relationship between the resulting feature "target" ("Asset growth, %") and the factorial feature X10 "Query frequency in Google, %", while the coefficient value was 0.902. There is a relatively strong positive relationship for the feature X4 "Share of bank assets in GDP" 0.396. As a result, the neural network DL-model formed a forecast of asset growth in 2025 of 6.56%, the VaR model showed 84.53%, the expert assessment method indicated 2.05%.

Keywords: DL-model, banking system, ensuring sustainable development, "Random Forest"

Дата поступления статьи в редакцию: 01.03.2025

Дата принятия статьи в печать: 28.04.2025

Введение

Актуальность обусловлена тем, что в условиях нарастающего санкционного давления со стороны недружественных стран, а также роста рыночной неопределенности, наблюдается тенденция роста количества научных работ, посвященных проблемам обеспечения устойчивого развития как отдельных коммерческих банков, так и всей отечественной банковской системы в целом. Практика показывает, что, несмотря на множество научных работ, посвященных этой проблеме, остается «некоторый научный разрыв» в тех областях знаний о понятиях «устойчивое развитие», «оценка устойчивости», «специфика устойчивости банка в условиях цифровизации».

Среди проблем, имеющих в банковском секторе, по мнению Казаренкова Н.П., наиболее важной является проблема формирования стратегии эффективного развития банковского и реального секторов экономики на основе эффекта конвергенции [1].

Представляется целесообразным формирование направлений повышения эффективности сотрудничества банковского сектора и реальной экономики. Автор считает, что банкам следует

- 1) сфокусироваться на диверсификации бизнеса для обеспечения необходимой рентабельности кредитования на приемлемом уровне;
- 2) формировать стабильные пассивы, получать процентную маржу на привлекательном уровне;
- 3) применять комплексный подход к обслуживанию, развивать корпоративный бизнес банка;
- 4) при условии экономической целесообразности участвовать в создании банковских синдикатов для финансирования крупных инвестиционных проектов;
- 5) софинансирование в форме создания финансово-промышленных групп;
- 6) широкое внедрение «кредитных фабрик», что в современных условиях получило название «цифровых экосистем».

По мнению автора, взаимодействие банков с предприятиями, которое наблюдается в российской экономике, его состояние и характер могут быть охарактеризованы как состояние «устойчивого плохого равновесия». Данное обстоятельство подтверждается тем, что низкая эффективность работы предприятий требует крупных инвестиций для крупномасштабной модернизации, что обуславливает потребность в крупных банковских кредитах, которые, к сожалению, не могут быть им предоставлены по причине неудовлетворительного финансового состояния этих предприятий.

Ряд экспертов усматривают резервы стабильного развития и устойчивого роста банковского сектора на основе анализа и оценки кредитных рисков и риска банкротства кредитной организации. Так, авторы Клаас Я.А., Клаас Т.А. работая над идентификацией факторов риска банкротства банков на основе использования разработанных моделей, утверждают, что ими выявлена острая необходимость в разработке новых подходов к прогнозированию и ранней диагностике риска банкротства кредитных институтов [2, с. 19-32]. Опираясь на результаты исследований российских и зарубежных ученых, ученые пришли к выводу, что существующие механизмы выявления проблемных банков на ранних стадиях, которые можно подразделить на четыре группы. В первую группу входят системы раннего предупреждения риска банкротства, например, FIMS, Bank Calculator, EWS, z-score, TRAM, SCOR, SAABA, GMS. Во вторую — системы дистанционного мониторинга, такие, как: BAKIS, GHE method и другие.

В третью были включены рейтинговые системы, такие, как, UBSS, PATROL, CAMELS, CAEL, ORAP. Ну и в четвертую авторы включили комплексные системы для оценки риска: RAST, RATE.

В список анализируемых параметров, характеризующих устойчивость кредитных организаций, авторами были выделены следующие общеизвестные:

- показатель, отражающий уровень достаточности основного капитала H1.2;
- отношение некоторой величины в совокупном исчислении, а именно, крупных кредитных рисков к капиталу H7;
- коэффициент, показывающий отношение имеющихся ликвидных активов к краткосрочным обязательствам кредитной организации H3.

В процессе добавления к ним фондового риска или был выведен «Коэффициент банкротства».

Свою точку зрения предложила автор Васильева А.Ф. в ходе разработки методов для расширения временного горизонта прогнозирования кредитного риска и повышения точности оценки ожидаемых кредитных потерь в пределах периода экспирации финансовых инструментов российских банков [3].

Буровой И.В. была предложена разработанная собственная математическая модель вероятности банкротства кредитных организаций, которая использовала алгоритм бинарной логистической регрессии [4, с. 123-129]. В ходе проведения исследования автор использовал информация о банках, у которые были отозваны лицензии на протяжении 2018 года, как известно, что в том году ЦБ РФ отозвал лицензии у 60 кредитных организаций.

В ходе исследования автор делает вывод, что с ростом величины чистой ссудной задолженности и приростом стоимости выпущенных долговых обязательств повышается вероятности банкротства банка. И наоборот, с ростом обязательных резервов, вкладов физлиц и индивидуальных предпринимателей, а также с увеличением нераспределенной прибыли и собственных средств, наблюдается повышение финансовой устойчивости кредитной организации.

В своем исследовании Мамзина Е.В. предложила разработанную ею эффективную систему управления рисками в коммерческом банке [5, с. 393-400]. Важнейшим аспектом в процессе формирования предложенной системы управления рисками является определение горизонта планирования. Важной частью разработанной стратегии управления рисками является наличие разных временных горизонтов, в которых предусмотрена комбинация различных возможным сценариев развития событий, сопряженных с различным уровнем риска.

Среди факторов устойчивости Гуров И.Н. с коллегами выделяют отток депозитов населения на основе интенсивности поисковых запросов [6, с. 92-104]. Авторами предложен механизм учета информации о динамике поисковых запросов в Яндекс wordstat, Google Trends, с помощью которого представляется возможным заблаговременно получить сигнал об изменениях объемов депозитов физических лиц в коммерческих банках. Исследование показало, что использование превентивной индикации неблагоприятных тенденций, а именно признаков приближающегося оттока депозитов населения, позволяет обеспечить устойчивость кредитного учреждения к негативным воздействиям внешних факторов, под действием дестабилизирующих макроэкономических факторов.

Проблема устойчивого развития находится в центре внимания зарубежных экспертов, которые выделяют множество аспектов этой проблемы. Так, например, прогнозированию финансовых трудностей для организационной устойчивости, с позиций эмпирического анализа, посвятили свое исследование авторы Сумья Ранджан Сетхи (Soumya Ranjan Sethi) и Душьянт Ашок Махадик (Dushyant Ashok Mahadik) [7]. Операционные исследования на основе методов искусственного интеллекта в банковской сфере проводил Михалис Думпос (Michalis Doumpos) с соавторами [8]. По мнению авторов, применение искусственного интеллекта (AI) в банковском деле является популярной темой для проведения различных эмпирических и методологических исследований, в том числе и в русле обеспечения устойчивого развития банков.

Среди методов искусственного интеллекта следует отметить такой метод, как «дерево решений» (DT), в основе которого лежит использование непараметрического метода обучения с учителем, который обеспечивает проведение как классификации, так и регрессии. При этом, как показала практика, следует использовать не одно, а несколько деревьев решений «ансамбль решающих деревьев», применение данного метода основано на использовании специальных библиотек в языке Python.

Данный метод получил название «Случайный лес» (Random forest), известный как алгоритм машинного обучения, применяемый для решения задач классификации и регрессии. Описание принципов работы настоящего метода нашло отражение многих работах, в частности, в работах Лоупе (Loupre) [9].

Цель исследования

Цель настоящего исследования состоит в том, чтобы сформировать модель глубокого обучения «Random Forest Regression» для получения прогнозного значения параметра «Прирост активов, %» в целях устойчивого развития банковской системы. В последующем сравнить его с прогнозом, полученным на основе VaR-модели, основанной на применении статистических методов. Динамика развития банковской системы представлена на рисунке 1.




Рис. 1. Изменение доли активов банков в ВВП и темпов прироста активов банков

В настоящем исследовании была сформирована DL-модель «Random Forest Regression» позволяющая получить прогноз параметра «Прирост активов, %». Кроме того, был проведен расчет прогнозного значения величины прироста активов с использованием VaR-модели с последующим сравнением полученных прогнозов прироста активов банковской системы, в качестве параметра ее устойчивости.

Материал и методы исследования

Принцип работы алгоритма «Случайный лес» состоит в том, что он формирует некоторое заданное множество решающих деревьев на основе настройки гиперпараметров модели. Каждая из которых случайным (случайным) образом подбирает те или иные факториальные признаки, изначально включенные в датасет модели, обучается на сформированном множестве, находит закономерности, и на основе заложенного алгоритма и найденных закономерностей делает прогноз. Затем проводится голосование за лучший результат, имеющий самую маленькую ошибку прогноза и это дерево признается лучшим из всего «ансамбля» решающих деревьев случайного леса. Этот алгоритм снижает эффект переобучения и повышает качество предсказаний.

В целях формирования нейросети была собрана и обработана исходная информация, обучение DL-модели проходило в облачном сервисе Google Collab с использованием языка Python [6]. Среди параметров, включенных в модель следует отметить следующие: X1 – ВВП, млрд. руб.; X2 – РТС индекс; X3 – Активы банков, млрд. руб.; X4 – Доля активов банков в ВВП, %; X5 – Депозиты физлиц Сбербанка, млрд. руб.; X6 – Прирост депозитов Сбербанка, %; X7 – Ключевая ставка на конец года, %; X8 – Чистая прибыль Сбера, млрд. руб.; X9 – Доля просроченных ссуд в банках свыше 90 дней, %; X10 – Частота запроса в Google, %; Y – Темпы прироста активов банков, %.

Рассмотренные показатели имеют важное значение для формирования нейросетевой модели устойчивости банковской системы РФ. Представляется целесообразным рассмотреть показатель «Темп прироста активов банков» в качестве показателя устойчивости ее развития (рис. 2).




Рис. 2. Динамика темпов прироста активов банков в банковской системе

Следует отметить, что темпы прироста активов банков в значительной мере определяют долю активов банков в ВВП (рис. 3).




Рис. 3. Визуализация взаимосвязи между темпами прироста активов банков (левая ось) и долей активов банков в ВВП (правая ось)

Как показали исследования, обеспокоенность населения в значительной мере проявляется в запросах в поисковиках и может быть зафиксирована браузером. Эта информация в последующем будет использована в нейросетевой модели в целях получения прогноза. Динамика частоты поисковых запросов «Где купить валюту?» за период 2013-2025 гг. представлена на рисунке 4.

Важно отметить, что можно заметить взаимозависимость между частотой запросов населения в браузере Google и темпами прироста активов банков и (рис. 5).

Датасет был успешно сформирован и размещен на Google-disk. Нейросетевая модель DL-модель «Random Forest Regressor» была выполнена с использованием таких библиотек как sklearn, numpy, pandas, а также matplotlib или seaborn на Google Colab. Так, например, библиотека sklearn позволяет пользоваться широким спектром инструментов, позволяющих провести предобработку, моделирование, оценку и развертывание моделей машинного обучения. Датасет нейросетевой модели «Random Forest» представлен в таблице 1.



Рис. 4. Динамика частоты поисковых запросов «Где купить валюту?»




Рис. 5. Взаимосвязь частотой запросов населения в браузере Google и темпами прироста активов банков

Таблица 1

Датасет нейросетевой модели «Random Forest»

	ВВП, X1	РТС, X2	Активы банков, млрд. руб., X3	Доля активов банков в ВВП, %, X4	Депозиты физлиц Сбербанка, X5	Прирост депозитов Сбербанка, %, X6	Ключевая ставка на конец года, %, X7	Чистая прибыль Сбера, млрд. руб., X8	В банках доля просроченных ссуд свыше 90 дней, X9	Частота запроса в Google, %, X10	Темпы прироста активов банков, %, Y
2024	200039,5	893,22	199243	99,6	15725	-31,8	21	1584,0	3,4	18	5,88
2023	176413,9	1073,14	167830	95,1	23066	46,7	16	1509,0	4,2	17	-5,56
2022	155188,9	970,6	134620	86,7	18633	-19,2	7,5	270,5	8,0	20	17,65
2021	135773,8	1595,76	120272	88,6	17345	-6,9	8,5	1251,0	4,2	9	-55,00
2020	107658,1	1387,46	103713	96,3	15710	-9,4	4,25	761,1	4,5	12	33,33
2019	109608,3	1548,92	88735	81,0	13625	-13,3	6,25	845,0	5,4	11	-8,33
2018	103861,7	1068,72	85725	82,5	20897,3	53,4	7,75	831,7	7,5	16	45,45
2017	91843,15	1154,43	78183	85,1	19814,2	-5,2	7,75	674,0	9,3	13	-18,75
2016	85616,08	1152,33	74276	86,8	18684,8	-5,7	11	517,0	10,5	8	-38,46
2015	83087,36	757,04	78282	94,2	19798,3	6,0	11	222,9	7,9	11	37,50
2014	79030,04	790,71	77700	98,3	15562,9	-21,4	17	305,7	5,8	39	254,55
2013	72985,7	1442,73	57400	78,6	12064,2	18,5	5,5	392,6	4,6	19	18,9

Применение библиотеки `numpy` позволяет эффективно работать с массивами, очень быстро выполняя большие вычисления за очень короткое время. Разделение данных на обучающие и тестовые наборы, является важной фазой предварительной обработки датасета. Для этого используется библиотека `pandas`, которая позволяет применять удобные инструменты для загрузки данных и последующего их разделения на тренировочные и тестовые выборки, с последующей настройкой и обучением. Модель позволяет определить зависимости между признаками, включенными в модель, парные коэффициенты корреляции представлены в таблице 2.

Таблица 2

Коэффициенты парной корреляции, рассчитанные DL-моделью

	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	target
X1	1.000	-0.113	0.986	0.410	0.253	-0.095	0.505	0.766	-0.481	-0.050	-0.310
X2	-0.113	1.000	-0.199	-0.555	-0.431	0.045	-0.644	0.225	-0.298	-0.496	-0.525
X3	0.986	-0.199	1.000	0.549	0.246	-0.137	0.601	0.767	-0.512	0.010	-0.222
X4	0.410	-0.555	0.549	1.000	0.190	-0.315	0.706	0.293	-0.334	0.338	0.396
X5	0.253	-0.431	0.246	0.190	1.000	0.524	0.208	0.192	0.404	-0.190	-0.185
X6	-0.095	0.045	-0.137	-0.315	0.524	1.000	-0.169	0.139	0.028	-0.146	-0.132
X7	0.505	-0.644	0.601	0.706	0.208	-0.169	1.000	0.429	-0.240	0.451	0.327
X8	0.766	0.225	0.767	0.293	0.192	0.139	0.429	1.000	-0.599	-0.237	-0.406
X9	-0.481	-0.298	-0.512	-0.334	0.404	0.028	-0.240	-0.599	1.000	-0.201	-0.084
X10	-0.050	-0.496	0.010	0.338	-0.190	-0.146	0.451	-0.237	-0.201	1.000	0.902
target	-0.310	-0.525	-0.222	0.396	-0.185	-0.132	0.327	-0.406	-0.084	0.902	1.000

```
[ ] 1 X = dataset.drop(['target'], axis=1)
    2 y = dataset['target']

[ ] 1 from sklearn.model_selection import train_test_split
    2 X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.20)

[ ] 1 from sklearn.tree import DecisionTreeRegressor
    2 regressor = DecisionTreeRegressor()
    3 regressor.fit(X_train, y_train)

[ ] 1 print(regressor.score(X_train, y_train))
```

Рис. 6. Скрипт программы DL-модели на языке Python




Рис. 7. «Тепловая» карта парных коэффициентов корреляции



Рис. 8. Лучшее дерево из «ансамбля деревьев» решений

Как показали исследования, наблюдается положительная сильная связь между результативным признаком «target» и факториальным признаком X10 «Частота запроса в Google,%», при этом величина коэффициента составила 0,902. Относительно сильная положительная связь отмечена у признаков X4 «Доля активов банков в ВВП» 0,396 и X7 «Ключевая ставка на конец года,%» 0,327. Довольно сильная отрицательная связь наблюдается с факториальным признаком X2 «РТС индекс» -0,525. Слабая отрицательная связь отмечена у фактора X1 «ВВП, млрд. руб.» -0,310. Для случайного разделения датасета на обучающий и тестовый наборы, был использован следующий скрипт (рис. 6).

В целях визуализации данных используют «тепловую» карту парных коэффициентов корреляции (рис. 7).

Визуализация лучшего дерева представлена на рисунке 8.

В процессе исследования использовалась библиотека Scikit-learn, позволившая получить параметры линейной многофакторной регрессии. Уравнение регрессии приняло вид:

$$Y = 568.148 - 0.002678 \cdot X_1 - 0.303461 \cdot X_2 + 0.003166 \cdot X_3 - 0.306224 \cdot X_4 - 0.020578 \cdot X_5 + 0.447249 \cdot X_5 + 1.130486 \cdot X_6 + 0.187752 \cdot X_7 + 0.582789 \cdot X_8 + 4.410357 \cdot X_9. \quad (1)$$

Найдем прогнозное значение величины прироста активов банковской системы на следующий 2024 году. Для расчета прогнозного значения на следующий год следует в уравнение подставить значения (2024 г.) из датасета:

$$Y = -0.002678 \cdot 200039.5 - 0.303461 \cdot 893.22 + 0.003166 \cdot 199243 - 0.306224 \cdot 99.6 - 0.020578 \cdot 15725 + 0.447249 \cdot (-31.8) + 1.130486 \cdot 21 + 0.187752 \cdot 1584 + 0.582789 \cdot 3.4 + 4.410357 \cdot 18. \quad (2)$$

Прогнозное значение факториального признака модели «Темпы прироста активов банков,%» составило -141.7, что находится примерно на уровне средней абсолютной ошибки 115.45, которая характеризует качество работы модели. Уровень ошибки прогнозирования DL-модели характеризуется параметрами, представленными в таблица 3.

В исследовании использовалась VaR-модель (Value at Risk), в основе которой лежит метод, помогающий рассчитать финансовый риск. При этом метод позволяет выразить в денежных единицах оценку величины потерь, которая с определенной вероятностью не сможет быть превышена в течение данного периода времени. В нашем случае оценивалась величина потерь стоимости активов банковской системы. Величина VaR представляет собой функцию временного горизонта расчёта и некоторого доверительного уровня – вероятности, с которой финансовые потери не превысят VaR. Доверительный уровень обычно устанавливается в зависимости от предпочтений к риску, как правило, от 95 до 99%. Расчеты прогнозного значения величины банковских активов VaR-моделью были проведены в XL-таблиц, использовался пакет «Анализ данных» (рис. 10).

Для расчета прогнозного значения на следующий тайм-фрейм (год) использовалась формула:

$$P_{t+1} = (q + 1) \times P_t, \quad (4)$$

$$P_{t+1} = (0.845 + 1) \times 199243 = 367603.3. \quad (5)$$

То есть прирост активов возрастет с 199243 до 367603,3 млрд рублей, то есть в $1,845 = \frac{367603.3}{199243}$

раза (почти удвоится). Эксперты РБК допустили сжатие прибыли банков из-за проблемных кредитов. 2025 год для российских банков несет высокую неопределенность с точки зрения финансового результата: чистая прибыль сектора может сохраниться на уровне этого 2024 года и составить до 4,1 трлн рублей или сжаться до 3,6 трлн рублей. Велика вероятность, что прирост активов составил 4,1 трлн рублей, или 2,05%. Нейросеть дала прогноз 6,56%, VaR-модель 84,53%, метод экспертных оценок 2,05% (рис. 11).




Рис. 11. Прогнозные значения прироста величины банковских активов на 2025 г.

Прогноз динамики величины банковских активов на 2025 год для российских банков сопряжен с его сложностью из-за высокой неопределенности и действия множества факторов.

Результаты исследования и их обсуждение

Проведенное исследование показало, что к важнейшим направлениям дальнейших возможных исследований можно отнести такие, как:

- 1) повышение точности получаемых прогнозов на основе использования гиперпараметров деревьев в ансамбле «случайного леса», в частности, количество деревьев в ансамбле, их глубина, критерии оптимального отбора на основе получаемых решений;
- 2) расширение линейки методов исследования, поскольку в целях прогнозирования могут быть использованы сверточные нейронные сети CNN, а также могут быть применены когнитивные и гибридные киберфизические системы.

Как известно, повышение точности и снижение финансового риска при прогнозировании временных рядов фьючерсных контрактов SIU0 с использованием нейронной сети с помощью метода Word2vec, было предметом исследования коллектива авторов во главе с Ломакиным Н.И. [10]. Перспективным направлением, как показала практика, является применение когнитивных моделей и гибридных киберфизических

систем, которые находятся в центре внимания многих современных ученых, в том числе Ломакина Н.И. с соавторами [11, 12]. Ученый Мэй Ли (Mei Li) с соавторами в целях повышения точности получаемых прогнозов цен на природные ресурсы, применяли гибридный искусственный интеллект [13].

Среди научных работ зарубежных ученых заслуживают внимания ряд отдельных исследований. Так, например, результаты от эффекта заражения искусственного интеллекта в инновационных отраслях, как, например, от блокчейна исследовали авторы Мухаммад Абубакр Наим (Muhammad Abubakr Naeem), Надя Арфауи (Nadia Arfaoui), Лариса Яровая (Larisa Yarovaya) [14]. По мнению авторов, искусственный интеллект является преобразующей силой в бизнесе, технологиях и науке, но его широкомасштабное влияние на процессы внедрения инноваций в отраслях остается недостаточно изученным. Авторы предприняли попытку рассмотреть взаимосвязь между искусственным интеллектом и ключевыми секторами, такими как банковский сектор, криптовалюта, блокчейн и другими.

Авторы Сумья Ранджан Сетхи (Soumya Ranjan Sethi) и Душьянт Ашок Махадик (Dushyant Ashok Mahadik) исследовали прогнозирование финансовых трудностей для организационной устойчивости с позиций эмпирического анализа [15].

Заслуживает внимание результаты операционных исследований и использованных методов искусственного интеллекта в банковской сфере, проведенных Михалисом Думпосом (Michalis Doumpos) и группой ученых [16]. Общеизвестно, что банковское дело является популярной темой, как для эмпирических, так и методологических исследований, в которых применяются методы операционных исследований (OR) и искусственного интеллекта (AI). Авторы представили всесторонний и структурированный библиографический обзор исследований на основе OR и AI, посвященных банковской отрасли. Авторами рассмотрены основные темы разработок, включая эффективность банковской деятельности и устойчивости, а также вопросы, связанные с оценкой рисков, эффективностью банков и финтех в банковской отрасли.

Безусловно, одним из важных направлений исследований, в котором Шармин Нахар (Sharmin Nahar) получил результаты, является моделирование влияния инноваций касательно целей устойчивого развития (ЦУР), применяя искусственный интеллект (ИИ) при изучении системной динамики в условиях межстранового взаимодействия [17]. Заслуживает внимания результат Дебидутта Паттнаик (Debidutta Pattnaik) полученный в ходе применения искусственного интеллекта и машинного обучения в сегменте финансовых услуг, в частности, в области библиометрической идентификации [18]. Авторы рассмотрели состояние исследований приложений искусственного интеллекта (ИИ) и машинного обучения (ML) и их применение в банковском, финансовом и страховом секторах (BFSI). Исследуя статьи, индексируемые в Scopus, для выявления ключевых исследовательских кластеров, провели анализ сопутствующей встречаемости и выявили девять различных кластеров. Среди них авторы выделили: финтех, управление рисками, борьбу с отмыванием денег, актуарную науку и другие. Поскольку эти кластеры предлагают всесторонний обзор многогранного исследовательского ландшафта, авторы использовали выявленные кластеры, поскольку они могут служить руководством для будущих исследований и информировать о дизайне исследования.

Исследовал искусственный интеллект (ИИ), финансовую стабильность и финансовый кризис Петерсон К. Озили (Peterson K. Ozili) [19]. По мнению автора, искусственный интеллект (ИИ) открывает новые возможности и риски в финансовой системе. Это приводит к усилению старых рисков и появлению новых. Финансовые регуляторы и органы банковского надзора знают обеспокоены разрушительным воздействием искусственного интеллекта и переживают, что системы ИИ могут увеличить риски для финансовой стабильности и спровоцировать финансовый кризис. Увеличивается риски взаимозависимостей, искажения рынка и манипулирования, более того, благодаря своему потенциалу увеличивать стадное поведение, касательно предложений, вводящих в заблуждение некорректных интерпретаций решений с помощью ИИ. Все это может способствовать усугублению формирующихся кризисов, увеличивая риск и скорость массового изъятия цифровых вкладов из банков, повышая скорость принятия решений, что может усилить стресс в плохие времена и тем самым спровоцировать кризис.

Выводы

В ходе проведенного исследования были достигнуты следующие результаты:

1. Выявлены основные тенденции применения искусственного интеллекта в сфере финансов и банковской сфере.
2. Сформирована DL-модель для получения прогноза результативного признака «Прирост активов,%».
3. Выявлена положительная сильная связь между результативным признаком «target – Прирост активов» и факториальным признаком X10 «Частота запроса в Google,%», при этом величина коэффициента

составила 0,902. Относительно сильная положительная связь отмечена у признаков Х4 «Доля активов банков в ВВП» 0,396 и Х7 «Ключевая ставка на конец года, %» 0,327. Довольно сильная отрицательная связь наблюдается с факториальным признаком Х2 «РТС индекс» -0,525.

4. Доказана выдвинутая гипотеза, о том, что можно получить прогноз параметра «Прирост активов, %» банковской системы, на основе использования DL-модели «Random Forest Regression».

5. Получены прогнозные значения «Прирост активов, %» разными методами: нейросеть дала прогноз 6,56%, VaR-модель 84,53%, метод экспертных оценок 2,05%.

Литература

1. Казаренкова Н.П. Анализ и оценка результатов взаимодействия банковского и реального секторов российской экономики // *Финансы и кредит*. 2015. № 47. С. 44-56.
2. Клаас Я.А., Клаас Т.А. Идентификация факторов риска банкротства кредитных организаций и их моделирование // *Финансы и кредит*. 2018. Т. 24. № 1 (769). С. 19-32.
3. Васильева А.Ф. Методы оценки кредитных рисков банковских финансовых инструментов на различных временных горизонтах: дис. ... канд. экон. наук, Москва, 2023. 253 с.
4. Бурова И.В. Построение математической модели вероятности банкротства кредитных организаций на основе бинарной логистической регрессии // *Региональные проблемы преобразования экономики*. 2021. № 3 (125). С. 123-129.
5. Мазнина Е.В. Эффективная система управления рисками коммерческого банка: ее архитектура и признаки // *Экономика: вчера, сегодня, завтра*. 2022. Т. 12. № 4-1. С. 393-400.
6. Гуров И.Н., Картаев Ф.С., Виноградова О.С. Прогнозирование оттока депозитов населения на основе интенсивности поисковых запросов // *Финансы: теория и практика*. 2023. Т. 27. № 3. С. 92-104.
7. Soumya R.S., Dushyant A.M. Forecasting financial distress for organizational sustainability: An empirical analysis // *Sustainable Futures*. 2025. Vol. 9. P. 100429. DOI: 10.1016/j.sfr.2024.100429.
8. Louppe G., Wehenkel L., Suter A., Geurts P. Understanding variable importances in forests of randomized trees. 2020. P.9-10. [Электронный ресурс]. URL: https://www.researchgate.net/publication/264046801_Understanding_variable_importances_in_Forests_of_randomized_trees (дата обращения 21.02.2025).
9. Michalis D., Constantin Z., Dimitrios G., Emmanouil P., Wenke Z. Operational research and artificial intelligence methods in banking // *European Journal of Operational Research*. 2023. Vol. 306. N 1. P. 1-16. DOI: 10.1016/j.ejor.2022.04.027.
10. Lomakin N., Kulachinskaya A., Maramygin M., Chernaya E. Improving Accuracy and Reducing Financial Risk When Forecasting Time Series of SIU0 Future Contracts Employing Neural Network with Word2vec Vector News // *Studies in Systems, Decision and Control* this link is disabled. 2022. Vol. 415. P. 281-298.
11. Ломакин Н.И., Кулачинская А., Цыганкова В.Н., Кособокова Е., Минаева О.А., Трунина В.Ф. Forecast of Stability of the Economy of the Russian Federation with the AI-System "Decision Tree" in a Cognitive Model // *International Journal of Technology (IJTech)*. 2023. Vol. 14, Is. 8. P. 1800-1809. DOI: 10.14716/ijtech.v14i8.6848.
12. Ломакин Н.И., Голодова О., Марамигин М., Кузьмина Т., Минаева О.А., Tudevdagva U. Hybrid Cyber-Physical System QUIK-LUA-Random Forest for Trading on MoEx. Creativity in Intelligent Technologies and Data Science: 5th International Conference CIT&DS 2023 (Volgograd, Russia, September 11-15, 2023): Proceedings / eds.: A.G. Kravets, M.V. Shcherbakov, P.P. Groumpos; Volgograd State Technical University [et al.]. Cham (Switzerland): Springer Nature Switzerland AG, 2023. P. 64-79. DOI: 10.1007/978-3-031-44615-3_5.
13. Mei L., Rida W., Dervis K., Ghazala A. Relevance of hybrid artificial intelligence for improving the forecasting accuracy of natural resource prices // *Geoscience Frontiers*. 2024. Vol. 15. N 3. P. 101670. DOI: 10.1016/j.gsf.2023.101670.
14. Abubakr M.N., Arfaoui N., Yarovaya L. The contagion effect of artificial intelligence across innovative industries: From blockchain and metaverse to cleantech and beyond // *Technological Forecasting and Social Change*. 2025. Vol. 210. P. 123822. DOI: 10.1016/j.techfore.2024.123822.
15. Soumya R.S., Dushyant A.M. Forecasting financial distress for organizational sustainability: An empirical analysis // *Sustainable Futures*. 2020. Vol. 9. P. 100429. DOI: 10.1016/j.sfr.2024.100429.
16. Doumpos M., Zopounidis C., Gounopoulos D., Platanakis E., Zhang W. Operational research and artificial intelligence methods in banking // *European Journal of Operational Research*. 2023. Vol. 306. N 1. P. 1-16. DOI: 10.1016/j.ejor.2022.04.027.
17. Sharmin N. Modeling the effects of artificial intelligence (AI)-based innovation on sustainable development goals (SDGs): Applying a system dynamics perspective in a cross-country setting // *Technological Forecasting and Social Change*. 2024. Vol. 201. P. 123203. DOI: 10.1016/j.techfore.2023.123203.
18. Debidutta P., Sougata R., Raghu R. Applications of artificial intelligence and machine learning in the financial services industry: A bibliometric review // *Heliyon*. 2024. Vol. 10. N 1. P. e23492. DOI: 10.1016/j.heliyon.2023.e23492.
19. Peterson K.O. Artificial Intelligence (AI), Financial Stability and Financial Crisis // *Reference Module in Social Sciences*. Elsevier. 2024. DOI: 10.1016/B978-0-443-13701-3.00487-4.