

КОНЦЕПЦИЯ МОДЕЛИ ПРОГНОЗИРОВАНИЯ ПРИЗНАКОВ ИЗМЕНЕНИЯ ЦЕНЫ АКЦИЙ, ПРЕДНАЗНАЧЕННОЙ ДЛЯ УПРАВЛЕНИЯ РИСКАМИ НЕФИНАНСОВЫХ ОРГАНИЗАЦИЙ**В. А. Востров^{1,a}, М. А. Гореликов^{1,2,b}, М. Е. Амелин^{3,c}**¹ Сургутский филиал федерального государственного автономного учреждения «Федеральный научный центр Научно-исследовательский институт системных исследований Национального исследовательского центра «Курчатовский институт», г. Сургут, Российская Федерация² Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В.И. Ульянова (Ленина), г. Санкт-Петербург, Российская Федерация³ Сургутский государственный университет, г. Сургут, Российская Федерация^a ORCID: <https://orcid.org/0009-0005-1647-4416>, ✉ valeriy-v-mail@mail.ru^b ORCID: <https://orcid.org/0009-0004-6196-5735>, gorelikov.matvey@mail.ru^c ORCID: <https://orcid.org/0009-0008-9831-2112>, makc_amelin@mail.ru

Аннотация: в статье предложена концепция проектирования интеллектуальной модели на основе нейронных сетей для проактивного управления финансовыми рисками нефинансовых компаний. Модель предполагает интеграцию данных финансовой отчетности с сайтов раскрытия информации, новостного потока из верифицированных источников и рыночных данных через API Московской биржи (MOEX), который предоставляет различные типы данных: исторические котировки, сделки, информация о позициях участников торгов и другие. Проект основан на анализе современного опыта и предполагает в том числе выявление предпосылок событий, способных оказать влияние на динамику цен на выбранные финансовые инструменты. В статье представлено обоснование выбранной архитектуры и решения с учетом специфики российского рынка.

Ключевые слова: методы искусственного интеллекта, интеллектуальные модели финансового риск-менеджмента, управление инвестициями на базе искусственного интеллекта, искусственный интеллект в сфере финансов.

Благодарности: работа выполнена в рамках государственного задания НИЦ «Курчатовский институт» — НИИСИ по теме № FNEF-2024-0001 «Создание и реализация доверенных систем искусственного интеллекта, основанных на новых математических и алгоритмических методах, моделях быстрых вычислений, реализуемых на отечественных вычислительных системах» (1023032100070-3-1.2.1).

Для цитирования: Востров В. А., Гореликов М. А., Амелин М. Е. Концепция модели прогнозирования признаков изменения цены акций, предназначенной для управления рисками нефинансовых организаций. *Успехи кибернетики*. 2025;6(3):20–26.

Поступила в редакцию: 08.07.2025.

В окончательном варианте: 28.08.2025.

A CONCEPT OF A MODEL FOR FORECASTING INDICATORS OF SHARE PRICE CHANGES TO MANAGE RISK IN NON-FINANCIAL ORGANIZATIONS**V. A. Vostrov^{1,a}, M. A. Gorelikov^{1,2,b}, M. E. Amelin^{3,c}**¹ Surgut Branch of Scientific Research Institute for System Analysis of the National Research Centre “Kurchatov Institute”, Surgut, Russian Federation² LETI Saint Petersburg Electrotechnical University, Saint Petersburg, Russian Federation³ Surgut State University, Surgut, Russian Federation^a ORCID: <https://orcid.org/0009-0005-1647-4416>, ✉ valeriy-v-mail@mail.ru^b ORCID: <https://orcid.org/0009-0004-6196-5735>, gorelikov.matvey@mail.ru^c ORCID: <https://orcid.org/0009-0008-9831-2112>, makc_amelin@mail.ru

Abstract: we developed a framework for an intelligent model based on neural networks to support proactive management of financial risks in non-financial companies. We collected financial reporting data from disclosure websites, news feeds from verified sources, and market data through the Moscow Exchange (MOEX) API, which provides historical quotes, trades, positions of trading participants, and other information. We analyzed current practices and identified prerequisites for events that may influence the price dynamics of selected financial instruments. We designed and justified the model’s architecture and selected solutions, taking into account the specific characteristics of the Russian market. The framework

integrates multiple data sources to improve risk prediction and support decision-making in financial risk management.

Keywords: artificial intelligence methods, intelligent financial risk management models, AI-based investment management, artificial intelligence for finance.

Acknowledgements: this study is a part of the FNEF-2024-0001 government order contracted to the Scientific Research Institute for System Analysis of the National Research Centre “Kurchatov Institute”, project No. 1023032100070-3-1.2.1 Development and Implementation of Trusted Artificial Intelligence Systems Based on new Mathematical Methods and Algorithms, Fast Computing Models for Domestic Computing Systems.

Cite this article: Vostrov V. A., Gorelikov M. A., Amelin M. E. A Concept of a Model for Forecasting Indicators of Share Price Changes to Manage Risk in Non-Financial Organizations. *Russian Journal of Cybernetics*. 2025;6(3):20–26.

Original article submitted: 08.07.2025.

Revision submitted: 28.08.2025.

Введение

Управление финансовыми рисками в нефинансовых компаниях приобретает критическую важность в условиях глобальной экономической нестабильности, включая санкционное давление, волатильность сырьевых рынков и изменения в российской регуляторной среде. Традиционные подходы к анализу рисков, основанные на финансовых коэффициентах (ликвидности, рентабельности, долговой нагрузки), ограничены задержками в публикации данных (1–3 месяца), их неоднородностью и недостаточной информативностью для раннего выявления угроз. Также стандартные методы не позволяют с необходимой скоростью учитывать влияние регуляторных изменений, например, повышение налогов, на стоимость активов [1]. Косвенные индикаторы, такие как новостные сообщения или динамика биржевых котировок, в большинстве случаев опережают официальную отчетность, предоставляя ценные сигналы о потенциальных рисках [2].

Помимо собственных результатов деятельности компании, значительное влияние на финансовое положение, а значит, и стоимость ценных бумаг эмитентов оказывают экзогенные факторы, важнейшим из которых являются решения государственных органов. Так, например, с 2025 года правительство повысило налог на прибыль индивидуально для ПАО «Транснефть» до 40%, что в день публикации этой новости в ноябре 2024 года вызвало падение акций на 8–9% (рис. 1) из-за ожидаемого сокращения дивидендов с 200 рублей до 156 рублей на акцию [3]. Аналогично увеличение налога на добычу полезных ископаемых (НДПИ) для ПАО «Газпром» с 2023 года на 600 млрд рублей ежегодно усилило финансовую нагрузку на компанию, что привело к отказу от дивидендов за 2023 год и снижению котировок акций к ноябрю 2024 года. Предпосылки таких решений — дефицит государственного бюджета, геополитические факторы, потребности в финансировании социальных программ — часто проявляются в новостном потоке задолго до их реализации, что демонстрирует необходимость их мониторинга для управления рисками.

Для эффективного управления финансовыми рисками необходима автоматизация процессов сбора и анализа данных. Традиционные подходы к автоматизации управления рисками, основанные на статистических методах ARIMA или GARCH, демонстрируют ограниченную эффективность при работе с нелинейными зависимостями, мультимодальными данными и неструктурированными источниками, такими как новостные потоки. Современные методы искусственного интеллекта, в частности нейронные сети, например многоуровневые LSTM, позволяют преодолеть эти ограничения, обеспечивая точное прогнозирование и выявление скрытых факторов риска [5]. При этом консолидация в единый программный комплекс статистической модели и модели искусственного интеллекта позволит объединить их преимущества. Программный комплекс на основе нейронных сетей и статистических моделей сможет интегрировать данные с официальных ресурсов для раскрытия отчетности компаний, API MOEX и новостные потоки для анализа косвенных признаков рисков резкого изменения цены актива и прогнозирования ее дальнейшей динамики.

В настоящей статье представлена концепция программного комплекса для автоматизированного анализа косвенных неспецифических превентивных признаков изменения финансовых показателей компаний и управления финансовыми рисками нефинансовых организаций. Комплекс объединяет статистические модели (ARIMAX, GARCH) и нейросетевые подходы (многоуровневая LSTM) для про-



Рис. 1. Котировки акций ПАО «Транснефть» [4]

гнозирования цен биржевых активов, оценки волатильности и формирования рекомендаций по минимизации рисков.

Задачи программного комплекса

Основные задачи, на решение которых направлен комплекс, включают в себя автоматизацию аналитических процессов для сокращения времени принятия управленческих решений и минимизации ошибок; выявление скрытых факторов риска с использованием нейронных сетей для обнаружения неявных зависимостей; интеграцию многоканальных данных, включая финансовые отчеты, рыночные данные и новостные потоки; поддержку проактивного принятия решений через сценарное тестирование; обеспечение масштабируемости и гибкости для адаптации к различным отраслям.

Данные и их источники

Предполагается, что в работе программного комплекса будут использоваться данные из следующих источников: платформа e-disclosure.ru, API Московской биржи (MOEX), новостных источников и макроэкономические индикаторы, публикуемые государственными органами.

Одним из важнейших факторов, оказывающих непосредственное влияние на динамику активов, являются финансовые показатели их эмитентов, которые собираются программным комплексом из официально раскрываемой отчетности на платформе e-disclosure.ru, предоставляющей публичные данные российских эмитентов. Рыночные данные (котировки ценных бумаг, объемы торгов и значения индексов) извлекаются через интерфейс API Московской биржи, обеспечивающий доступ к реальным данным в формате JSON. Новостные потоки анализируются на основе верифицированных источников, например, поискового интерфейса портала РБК, с которого возможно получение данных в формате JSON. Макроэкономические индикаторы, включая цены на нефть, золото, валютные курсы и уровень инфляции, получают из открытых источников, таких как Банк России и Росстат.

Для анализа изменения рыночных настроений и регуляторных изменений создается специализированный словарь терминов, включающий ключевые слова, наиболее часто встречающиеся в сообщениях, за которыми следуют ощутимые движения цен на соответствующие активы, например, «налоговое законодательство», «санкции», «регулирование рынков», «ожидаются убытки», «рост прибыли», «снижение ставок» и т.п. Этот словарь используется для фильтрации новостей, связанных с потенциальными изменениями настроений на рынке и изменений в законодательстве, которые могут повлиять на стоимость активов. Данные собираются в реальном времени или с заданной периодичностью, обеспечивающей актуальность прогнозов.

Анализ и трансформация данных

Для обучения LSTM-модели необходим согласованный временной ряд, в котором одна и та же календарная сетка содержит цену анализируемого актива, ключевые макроиндикаторы и объем торгов. Собранные данные подвергаются тщательной предобработке в целях обеспечения их пригодности для моделирования. Временные ряды цен нормализуются с использованием min-max масштабирования в диапазоне [0, 1], чтобы устранить влияние различных масштабов. Пропущенные значения заполняются методом линейной интерполяции, а для устранения нестационарности применяется дифференцирование первого порядка или логарифмирование. Для проверки стационарности рядов используется тест Дики–Фуллера [6].

Новостные тексты преобразуются в векторные представления с помощью русифицированной модели BERT [7] — RuBERT, позволяющей извлечь тональность (положительная, нейтральная, отрицательная) и ключевые темы. Для анализа значимых факторов применяется фильтрация текстов по словарю, что позволяет выделить новости, коррелирующие с анализируемым активом, а также учитывать эмоционально-информационный фон, влияющий на рыночные настроения.

Также создаются дополнительные признаки для повышения информативности данных:

- лаги цен за определенное количество торговых дней;
- скользящие средние;
- технические индикаторы: RSI (Relative Strength Index), MACD (Moving Average Convergence Divergence);
- макроэкономические показатели: цены на нефть, золото, курсы валют, инфляция, фондовые индексы.

Эти признаки формируют входной тензор для нейросетевой модели размером 10×5 (10 дней, 5 показателей). Текстовые данные агрегируются в виде векторов размером 768 (выход RuBERT), которые интегрируются с числовыми данными.

Построение моделей

Как указано выше, описываемый программный комплекс включает два аналитических модуля: статистический и нейросетевой.

Статистические подходы характеризуются тем, что они математически обоснованы, устойчивы при малом объеме данных и не требуют больших вычислительных ресурсов, что важно для регулярных обновлений. Однако их точность падает с увеличением горизонта прогноза, а методы машинного обучения, такие как нейронные сети, частично решают эту проблему [8, 9].

Включение в программный комплекс модели ARIMA (Autoregressive Integrated Moving Average) и ее расширения ARIMAX (с экзогенными переменными) обусловлено способностью эффективно моделировать временные ряды с учетом автокорреляции и трендов [10]. В отличие от простых методов (скользящее среднее или экспоненциальное сглаживание) ARIMA учитывает авторегрессионные и скользящие средние компоненты, а также дифференцирование для приведения нестационарных рядов к стационарным, что позволяет лучше улавливать сложные зависимости в данных, а ARIMAX при этом добавляет экзогенные переменные (например, экономические индикаторы или новости) и позволяет их учитывать с временными лагами [10–14].

В программном комплексе статистическая модель используется для прогнозирования краткосрочных отклонений цен от их среднего значения. ARIMAX моделирует запаздывающее влияние внешних факторов на цену актива, расширяя горизонт прогноза, работает со стационарными и нестационарными рядами после их преобразования, а экзогенные переменные (например, экономические индикаторы) влияют на целевую переменную, но слабо от нее зависят. Их релевантность подтверждается смысловой и статистической связью. Будущие значения экзогенных параметров обычно неизвестны, а их воздействие имеет лаги.

В предлагаемом подходе формирования краткосрочных прогнозов с использованием модели ARIMAX общий горизонт превышает краткосрочный за счет регулярного переобучения с учетом обновленных данных. Отбор экзогенных переменных начинается с корреляционного анализа и теста Грейнджера для определения лагов. Выбираются переменные с максимальной корреляцией и лагами, горизонт краткосрочного прогноза равен минимальному лагу. Также предполагается переобучение ARIMAX с периодичностью, равной горизонту прогноза, с адаптацией модели к текущим данным и внешним факторам.

При выборе модели искусственного интеллекта для программного комплекса были приняты во внимание следующие факторы. LSTM (Long Short-Term Memory) с ее механизмами памяти эффективно моделирует длительные временные зависимости в финансовых данных, превосходя базовые RNN, которым свойственна проблема исчезающего градиента [15], и CNN, ориентированные на пространственные, а не последовательные данные. Также LSTM легко адаптируется к резким колебаниям рынка, в отличие от трансформеров, которые требуют больших вычислительных ресурсов и больших данных для схожей точности [16].

Кроме того, LSTM легко сочетается с анализом настроений (например, через LLM или RuBERT) для учета новостей, улучшая прогнозы [17]. Это преимущество перед CNN, не предназначенными для последовательного анализа текста, и трансформерами, хотя те и превосходят LSTM в скорости обработки больших текстов.

В отличие от трансформеров, требующих больших объемов данных, LSTM демонстрирует хорошие результаты на умеренных наборах финансовых данных [18].

Хотя трансформеры и оптимизированы для параллельных вычислений на GPU, LSTM также эффективно использует GPU, но с меньшими требованиями к памяти, что делает ее практичной для системы с многошаговым прогнозированием [19].

Учитывая представленные данные, можно сделать вывод, что LSTM является оптимальной моделью для включения в программный комплекс.

Поток данных

Диаграмма на рисунке 2 отображает потоки данных между системами и базами данных рассматриваемого программного комплекса.




Рис. 2. Диаграмма потока данных в программном комплексе

Ключевыми элементами системы являются входные/выходные данные, точки хранения и сбора данных. Пользователь программного комплекса задает исходные настройки: выбирает активы и период. Эти данные попадают в блок «Параметризация» и сохраняются в базе.

Далее в блоке «Сбор и обработка данных», куда загружаются данные о валютных курсах, макроэкономические показатели и новости, осуществляется их очистка и ввод в таблицу. Готовый набор признаков вновь записывается в базу. Нейросеть тональности анализирует новости и помечает их как позитивные, негативные или нейтральные. LSTM-модель берет эти метки вместе с числовыми данными и строит прогноз цен, который направляется в базу данных.

Блок «Анализ рисков» получает из базы данных прогнозные ряды и проверяет показатели на соответствие заданным пределам. Его выводы и метрики риска сохраняются и передаются в модуль «Генерация отчетов».

Модуль отчетов создает графики и формирует итоговый файл с рекомендациями, после чего пользователь получает отчет и при необходимости проводит сценарный анализ, меняя исходные параметры.

В результате в базе данных формируется полный набор: параметры запуска, очищенные данные, прогнозы, расчет рисков и готовый отчет.

Заключение

Проведенный анализ исследований в области разработки предиктивных систем подтверждает эффективность гибридного подхода. Комбинация нейросетевой и статистической моделей направлена на улучшение точности прогнозирования по сравнению с отдельными моделями [20]. Интеграция в структуру программного комплекса модуля анализа текстовых данных позволит повысить эффективность комплекса за счет учета рыночных настроений.

ЛИТЕРАТУРА

1. Zhu X., Wang Y., Li J. What Drives Reputational Risk? Evidence from Textual Risk Disclosures in Financial Statements. *Humanities and Social Sciences Communications*. 2022;9(1). DOI: <https://doi.org/10.1057/s41599-022-01341-y>.
2. Ristolainen K., Roukka T., Nyberg H. A Thousand Words Tell More than Just Numbers: Financial Crises and Historical Headlines. *Journal of Financial Stability*. 2024;70:101209. DOI: <https://doi.org/10.1016/j.jfs.2023.101209>.
3. Что будет с акциями «Транснефти» в случае повышения налогов: прогнозы экспертов. *РБК*. Режим доступа: <https://www.rbc.ru/quote/news/article/673b29719a7947c91e6131b0>.
4. Данные торгового терминала Trading View о стоимости акций ПАО «Транснефть». Режим доступа: <https://ru.tradingview.com/chart/YNS9trTO/?symbol=RUS%3ATRNF#order>.
5. Fischer T., Krauss C. Deep Learning with Long Short-Term Memory Networks for Financial Market Predictions. *European Journal of Operational Research*. 2018;270(2):654–669. DOI: <https://doi.org/10.1016/j.ejor.2017.11.054>.
6. Dickey D. A., Fuller W. A. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*. 1979;74(366):427–431. DOI: <https://doi.org/10.2307/2286348>.
7. Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-Training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of NAACL-HLT 2019*. 2019:4171–4186. Режим доступа: <https://arxiv.org/abs/1810.04805>.
8. Нильсен Э. *Практический анализ временных рядов. Прогнозирование со статистикой и машинное обучение* / пер. с англ. СПб.: ООО «Диалектика»; 2021. 544 с.
9. Брюс П., Брюс Э., Гедек П. *Практическая статистика для специалистов Data Science* / пер. с англ. 2-е изд., перераб. и доп. СПб.: БХВ-Петербург; 2021. 352 с.
10. Box G. E. P., Jenkins G. M. *Time Series Analysis: Forecasting and Control*. Holden-Day; 1976. 589 p. Режим доступа: <https://djvu.online/file/DUly3RuKcHT1P?ysclid=mchob73nei436849235>.
11. Волков Н. Модели вида ARIMA. *Яндекс Образование*. Режим доступа: <https://education.yandex.ru/handbook/ml/article/modeli-vida-arima>.
12. Gujarati D. N. *Basic Econometrics*. 4th ed. New York: The McGraw-Hill Companies; 2004. 1002 p.
13. Davidson R., MacKinnon J. G. *Econometric Theory and Methods*. Oxford University Press; 2004. 765 p.
14. *ARIMA Model – Complete Guide to Time Series Forecasting in Python*. Режим доступа: <https://www.machinelearningplus.com/time-series/arima-model-time-series-forecasting-python/>.
15. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780. Режим доступа: <https://www.bioinf.jku.at/publications/older/2604.pdf>.
16. Hinton G. E., Srivastava N., Krizhevsky A., Sutskever I., Salakhutdinov R. R. Improving Neural Networks by Preventing Co-adaptation of Feature Detectors. 2012. *arXiv:1207.0580*. Режим доступа: <https://arxiv.org/abs/1207.0580>.

17. Ding X., Zhang Y., Liu T., Duan J. Deep Learning for Event-Driven Stock Prediction. *IJCAI Proceedings*. 2015:2327–2333. Режим доступа: <https://www.ijcai.org/Proceedings/15/Papers/329.pdf>.
18. Nelson D. M. Q., Pereira A. C. M., de Oliveira R. A. Stock Market's Price Movement Prediction with LSTM Neural Networks. *2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA*. 2017:1419-1426. DOI: 10.1109/IJCNN.2017.7966019. Режим доступа: <https://ieeexplore.ieee.org/document/7966019>.
19. Lipton Z. C., Berkowitz J., Elkan C. A Critical Review of Recurrent Neural Networks for Sequence Learning. 2015. *arXiv:1506.00019*. Режим доступа: <https://arxiv.org/abs/1506.00019>.
20. Roszyk N., Slepaczuk R. The Hybrid Forecast of S&P 500 Volatility Ensembled from VIX, GARCH and LSTM models. 2024. *arXiv:2407.16780*. Режим доступа: <https://arxiv.org/pdf/2407.16780>.