

УДК 004.8 DOI: 10.14451/1.254.92

Применение нейросетевых технологий для анализа стоимостных показателей

© 2026 **Дагаев Александр Владимирович**

Кандидат технических наук, доцент, кафедра информационных и промышленных технологий (Кафедра 2). Ивановский гуманитарно-технический институт (филиал ГУАП).

E-mail: adagaev@list.ru

© 2026 **Шепелева Ольга Петровна**

Кандидат сельскохозяйственных наук, доцент кафедры Бизнес-информатика. Финансовый университет при Правительстве РФ, Санкт-Петербургский филиал.

E-mail: opshepeleva@fa.ru

© 2026 **Калиновский Андрей Валентинович**

Кандидат экономических наук, доцент, кафедра Бизнес-информатика. Финансовый университет при Правительстве РФ, Санкт-Петербургский филиал.

E-mail: avkalinovskij@fa.ru

Ключевые слова: нейросетевые модели, набор данных, прогнозирование, индикаторы рынка, метрики точности.

В данной работе представлен комплексный подход к прогнозированию цен акций, объединяющий методы технического анализа и анализа тональности новостного и социального текста. Используется предобработка данных, включающая очистку, нормализацию и генерацию признаков, на основе которых строятся временные ряды. Для моделирования временной динамики цен применяется рекуррентная нейронная сеть Long Short-Term Memory (LSTM), оптимально подходящая для захвата долгосрочных зависимостей на финансовых временных рядах. Для оценки настроений рынка и новостного фона задействованы современные трансформерные модели BERT (Bidirectional Encoder Representations from Transformers) и GPT (Generative Pre-trained Transformer), которые позволяют извлекать и классифицировать тональность текста, влияющую на движение рынка. В расчет также включены широко используемые технические индикаторы: скользящая средняя (SMA), конвергенция/дивергенция скользящих средних (MACD), индекс относительной силы (RSI), средний истинный диапазон (ATR) и другие, расширяющие признаки модели технического анализа. Интеграция данных источников и методов позволяет улучшить точность и надежность прогнозов, что продемонстрировано на исторических данных фондового рынка. Результаты показывают потенциал комбинированных моделей для поддержки инвестиционных решений и управления рисками.

Развитие искусственного интеллекта и методов машинного обучения стало одной из ключевых тенденций современной экономики, радикально изменив подход к анализу и прогнозированию финансовых рынков. По мере усложнения структуры мировых фондовых площадок, все более остро ощущается потребность в моделях, способных улавливать скрытые закономерности в динамике цен и реагировать на мельчайшие колебания информационного фона. Поэтому нейросетевые технологии, особенно глубокие архитектуры, постепенно вытесняют классические статистические методы и становятся инструментом первого выбора при прогнозировании котировок акций, что представлено в источниках [2; 3; 5]. В фундаментальных исследованиях, представленных в [1; 7], проводится сопоставление интегрированной модели авторегрессии ARIMA и рекуррентной нейронной сети LSTM, специально ориентированной на работу с временными рядами, имеющими долгосрочные зависимости, как показано в источниках. Также в источниках [11; 14] показано, что традиционная линейная модель удовлетворительно описывает лишь сглаженные тренды, тогда как LSTM демонстрирует способность «запоминать» протяженные фрагменты истории цен и тем самым точнее отражать сложную, нелинейную структуру финансовых данных. В статьях [1; 3; 7] внимание сосредоточено не только на сравнении точности прогноза, но и на анализе устойчивости моделей к изменению рыночного режима, что особенно важно в условиях высокой волатильности. Ряд исследований посвящен детальному рассмотрению применения сетей LSTM непосредственно для прогнозирования котировок акций на основе исторических рядов цен и торговых объемов, что представлено в [11; 14]. Авторы показывают, как выбор глубины сети, длины входного окна и регуляризационных приемов влияет на способность модели предсказывать краткосрочные движения рынка и снижать ошибки по метрикам MAPE и RMSE, зачастую заметно превосходя классические подходы [2; 3; 7]. Особый акцент делается на интерпретации результатов: визуальное сопоставление фактических

и прогнозных траекторий курсов демонстрирует, что LSTM лучше улавливает переломные точки тренда и локальные экстремумы [2; 3; 5]. Другие авторы источников [3–6] бращаются к более широкому спектру нейросетевых архитектур, исследуя прогнозирование параметров финансового рынка – индексов, волатильности, доходностей портфелей – с помощью полносвязных, сверточных и рекуррентных сетей. В этих работах подчеркивается специфика финансовой информации: шумность, наличие выбросов, смена режимов и существенная роль внешних макроэкономических и новостных факторов, что требует тщательной предварительной обработки данных и настройки регуляризации моделей. В статьях [8; 11; 14] показано, что включение в архитектуру механизмов внимания и многоуровневой нелинейной трансформации признаков позволяет повысить чувствительность моделей к слабым, но устойчивым сигналам рынка. В литературе последних лет выделяются также работы обзорного характера, где проводится систематический анализ применения нейронных сетей в задачах предсказания движений фондового рынка [8; 10; 11; 14; 15]. В таких обзорах сопоставляются результаты экспериментов с различными архитектурами – от классических многослойных перцептронов и CNN до LSTM и трансформеров, – а также обсуждаются вопросы качества данных, выбора признаков и устойчивости моделей к переобучению. Делается вывод о том, что нейросетевые подходы, при корректной настройке и наличии достаточного объема данных, демонстрируют заметное превосходство над традиционными статистическими методами и открывают новые горизонты для автоматизации и интеллектуализации процессов прогнозирования котировок акций.

Рассмотрим задачи моделирования подробнее. На сегодняшний день автоматизация биржевой торговли позволяет повысить скорость принятия решений и качество прогнозирования ценовых характеристик акций компаний. Прогнозирование цен акций традиционно является одной из ключевых задач финансового анализа

и экономики, привлекающей внимание исследователей и практиков из-за своей высокой сложности и экономической значимости. Рыночные цены формируются под влиянием множества факторов – от фундаментальных экономических показателей до новостного фона и психологического настроения участников рынка. В связи с этим эффективные модели предсказания должны учитывать как количественные временные ряды, так и качественные характеристики рыночного контента. Современные методы машинного обучения и глубоких нейронных сетей, таких как LSTM и BERT, хорошо зарекомендовали себя в обработке последовательных данных и нашли широкое применение в прогнозировании временных рядов, в том числе финансовых. Модель LSTM способна улавливать длительные зависимости и сезонные паттерны, характерные для цен акций. Текстовая информация из новостей, анализов и социальных медиа ресурсов играет все более важную роль в прогнозировании рынка. Для ее обработки применяются модели естественного языка на базе трансформеров BERT и GPT, которые позволяют эффективно выявлять тональность и эмоциональные оттенки текстов. Оценка настроения новостного потока помогает предвидеть изменения в поведении инвесторов и, как следствие, колебания цен. Помимо этого, технический анализ традиционно основывается на индикаторах, таких как SMA, MACD, RSI и ATR и др., служащих инструментами выявления трендов, уровней поддержки и сопротивления, а также оценки волатильности рынка. Их включение в модель расширяет возможности прогнозирования за счет структурированной информации о состоянии рынка. Настоящее исследование направлено на разработку интегрированной модели, объединяющей предобработку данных, LSTM для временного анализа, трансформерные модели для анализа тональности текста и классические технические индикаторы. Такой многокомпонентный подход позволяет повысить качество прогнозов и построить более обоснованные торговые стратегии.

Приведем основные характеристики архитектур и применяемых методов обработки данных. В мо-

дели LSTM-архитектура состоит из повторяющихся блоков ячеек с механизмом забывания, входного и выходного шлюзов, что позволяет запоминать долгосрочные зависимости. Ее преимуществом является устойчивость к затухающему градиенту, хорошо работает с временными рядами финансов. Однако она требует больших вычислительных ресурсов, чувствительна к шумам данных, эффективна для предсказания котировок акций за счет способности моделировать временные зависимости, но требует аккуратной настройки и внимания к особенностям финансовых временных рядов. Основными достоинствами сетей является их гибкость. Они могут обучаться на примерах сложных нелинейных динамик рынка и лучше адаптироваться к резким изменениям по сравнению с линейными моделями. Также преимуществом данных моделей является возможность обработки многомерных входов, вместе с ценами и объемами. В них можно включать другие признаки, такие как макроэкономические индикаторы, новости, индикаторы рыночной ликвидности, технические индикаторы, что позволяет строить более информативные модели. Также они поддерживают онлайн-обучение и обновление. Рекуррентные сети можно дообучать на новых данных, чтобы адаптироваться к новым рыночным условиям, снижая риск устаревания модели.

Модель BERT является двунаправленной трансформерной моделью с механизмом внимания, предобученная на больших объемах текста. BERT обучается на двунаправленной трактовке контекста слов, что позволяет распознавать нюансы финансового языка, такие как риск-термины, изменения в котировках, упоминания компаний и событий. Это повышает качество извлечения смысла из сложных новостных материалов. Ее основным преимуществом является точная оценка тональности, и контекстуальное понимание. Модель можно дообучать на финансово-ориентированных данных (fine-tuning), что позволяет адаптировать ее под специфическую лексику и бизнес-правила, характерные для финансовой журналистики и аналитики. Модель хорошо справляется




Рис. 1. Прогнозирование динамики акций.

с задачами классификации тональности, распознавания именованных сущностей (организации, финансовые инструменты, даты), а также с извлечением фактов и отношений между сущностями, что полезно для сводок новостей и торговых сигналов. Хорошая совместимость с длинными текстами через методики агрегации, которые обрабатывают длинные статьи в последовательностях и объединяют результаты, позволяет не терять значимые детали при ограничении моделей на число токенов. Это важно для полноты анализа в финансовых новостях. Недостатком BERT в анализе финансовых новостей является ограничение входа до примерно 512 токенов; длинные финансовые статьи требуют разбиения на фрагменты и сложной агрегации результатов, что может приводить к потере контекста и снижению точности. Возможен неполный учет сущностей и контекстных зависимостей. Так, в открытых наборах данных по анализу тональности, часто наблюдается симметричность просмотра всей новости без выделения ключевых сущностей и их влияния на восприятие новости, что снижает качество для финансового анализа, где сущности и их связи критичны (например, банкротство, регуляторные меры, санкции). Тогда требуется дообучение на задачах NER (Named Entity Recognition), направленных на выделение фрагментов в тексте, относящихся к классам и учета сущностей в контексте. Модели чувствительны к специфике финансового языка. Финансовый лексикон включает термины, аббревиатуры и контекстуальные сигналы, которые могут быть не полностью отражены

в общем английском и русском предобучении; без адаптации модель может давать нейтральные или ошибочно-положительные результаты на ключевых событиях., поэтому может потребоваться доменное дообучение и настройка порогов. Финансовые рынки быстро меняются, поэтому модели без постоянного обновления данных рискуют отставать и давать устаревшие сигналы. Необходимо регулярное обновление моделей и переобучение на свежих источниках. Как и многие трансформеры, BERT может давать результаты без явного объяснения причин (почему определенная новость считается позитивной/негативной). Для финансовых решений важна прозрачность выводов и возможность объяснить, какие фрагменты текста повлияли на оценку, что требует дополнительных методов explainable AI (объяснимого искусственного интеллекта). В данной работе использовалась модель BERT и в дальнейшем планируется использование более продвинутой сети

Ввиду ряда ограничений представленной выше модели, для анализа экономических показателей рынка сегодня больше используются специализированные финансовые модели, такие как FinBERT. Представим характеристики данной модели подробнее. Она представляет собой мощный инструмент для финансового анализа и прогнозирования, но требует балансировки между точностью, вычислительной эффективностью и интерпретируемостью для успешного внедрения в прикладные решения. Представим ее преимущества перед обычной моделью BERT. Модель позволяет лучше понимать

финансовый контекст за счет предобучения на рыночных данных и учёта технических индикаторов (SMA, MACD, RSI, ATR), что позволяет точнее распознавать важные финансовые события. Она работает с сущностями, которые могут быть представлены в виде отдельных слов, фраз или в виде их последовательностей, идентифицируя и категоризируя их в заранее выбранные группы. Она позволяет анализировать тональность новостного контента, что улучшает качество извлечения торговых сигналов. В модели поддерживается адаптация через процесс точной настройки (fine-tuning) для учета специфики языков и терминологии финансового рынка. Модель поддерживает гибкость в обработке различных типов данных (текст, числовые индикаторы), что способствует созданию комплексных прогнозных решений. К некоторым ее недостаткам можно отнести повышенную вычислительную сложность и необходимость больших ресурсов для обучения и инференса, что усложняет использование в реальном времени и на больших объемах данных. Ограничение по длине входных последовательностей (до 512 токенов) сохраняется, вызывая сложности с полнотой анализа длинных финансовых текстов и требуя сложных методов агрегации. Она обладает высокой чувствительностью к гиперпараметрам и риском переобучения из-за предобученной базы, имеет недостаточную прозрачность прогнозов, что ограничивает применение в системах, требующих объяснимых и поддающихся аудиту.

Опишем подробнее результаты исследования. В работе была разработана комплексная модель на базе LSTM, входными параметрами для которой служили данные из модели BERT, биржевые данные по котировкам акций и информация от индикаторов рынка, таких как: SMA, RSI, MACD, ATR и других. В начале была выполнена предобработка данных, наиболее важными моментами в предобработке данных явились этапы устранения эксцессов и нормализации данных. Моделирование выполнялось на дневных периодах, время измерялось в часах. Результаты тестирования модели носят положительный ха-

рактер, как показано на графике показанном на рисунке 1.

Также модель показывает хорошие результаты на средневолатильных данных, при низкой волатильности ей не хватает чувствительности, при большой динамике она не успевает качественно реагировать на поведение рынка. Эти недостатки можно устранять, используя более тонкие настройки модели. В дальнейшем планируется развитие модели для прогнозирования, ее настройка на небольших периодах времени, точность на которых на данный момент плавают. Для улучшения модели требуется дальнейшая разработка новостной экономической модели на базе FinBERT, оптимизация периодов обновления данных и дообучения модели, повышение качества и количества биржевой информации, также добавление индикаторов рынка и условий остановки торгов.

Заключение

В ходе проведенных исследований были разработаны композитные модели анализа и предсказания поведения стоимостных трендов и автоматизированной торговли. Применение технологий предобработки данных позволило повысить качество моделирования. Интеграция нескольких моделей потребовало дополнительного процесса их настройки и обучения. В работе использовались исторические стоимостные данные, новостной контент и технические индикаторы рынка, реализована гибкая архитектура модели, применено обучение с кросс-валидацией, а также механизмы сохранения и загрузки обученных моделей для повторного использования. Модель способна анализировать как краткосрочные, так и долгосрочные прогнозы для различных временных периодов. Для улучшения качества прогнозирования требуется доработка моделей и введение новых параметров. Дальнейшее их развитие потребует разработки и тестирования торговых роботов под определенные биржи и для определённых фирм, также реализации механизма условий и ограничений, в которых модели будут функционировать.

Библиографический список

1. Алжеев А. В. Сравнительный анализ прогнозных моделей ARIMA и LSTM для финансовых данных. – М. : Финансовый университет, 2020. – 120 с.
2. Бушуев М. В. Применение сети LSTM для прогнозирования котировок акций // Вестник высшей школы. – 2023. – № 4. – С. 15–24.
3. Грачев С. А. Прогнозирование параметров финансового рынка с применением нейронных сетей // Информационные технологии. – 2025. – № 1. – С. 44–50.
4. Дагаев А. В. Анализ данных с помощью методов машинного обучения : Международная научно-практическая конференция // Национальная экономика и развитие мирового хозяйства: проблемы и перспективы. – СПб. : Скифия-принт, 2024. – С. 55–62.
5. Дагаев А. В. Применение нейросетевых технологий для прогнозирования котировок акций : Международная научно-практическая конференция, посвященная 25-летию со дня образования Ивангородского филиала Санкт-Петербургского государственного университета аэрокосмического приборостроения // Право, образование, экономика в условиях цифровой трансформации. – СПб. : Скифия-принт, 2025. – С. 45–52.
6. Дагаев А. В., Бродянский Ю. М. Развитие нейросетевых моделей : Международная научно-практическая конференция // Актуальные проблемы управления в условиях новых вызовов внешней среды. – СПб. : Скифия-принт, 2025. – С. 36–42.
7. Щербинина А. В. Сравнительный анализ качества прогнозирования моделей ARIMA и LSTM // Scinotes. – 2021. – Т. 8, № 2. – С. 88–95.
8. A Deep Learning-Based LSTM for Stock Price Prediction Using Technical Analysis and Macroeconomic Data // International Journal of Intelligent Systems and Applications in Engineering. – 2023. – Vol. 11, no. 4. – P. 250–262.
9. Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding // Proceedings of NAACL-HLT. – Minneapolis, 2019. – P. 4171–4186.
10. Forecasting S&P 500 Using LSTM Models / arXiv preprint arXiv:2501.17366. – 2025. – 29 p.
11. From Data Extraction to Economic Insights: A Holistic Approach to Monetization / A. Titov [et al.] // Data-Driven Monetization Strategies for Economic Insights. – IGI Global Scientific Publishing, 09/2025. – P. 71–100. – ISBN 9798337327747. – DOI: [10.4018/979-8-3373-2772-3.ch004](https://doi.org/10.4018/979-8-3373-2772-3.ch004).
12. IBM T. J. Watson Research Center. Modality-aware Transformer for Financial Time Series Forecasting / arXiv preprint arXiv:2310.01232. – 2024. – 18 p.
13. Lezmi E., Xu J. Time Series Forecasting with Transformer Models and Application to Asset Management // SSRN Electronic Journal. – 2023. – Jan. – DOI: [10.2139/ssrn.4375798](https://doi.org/10.2139/ssrn.4375798).
14. Popularization of Domestic Tourism in Russia Through a Cross-Platform Mobile Application : Lecture Notes in Networks and Systems, vol 1521 / V. Nikiforov [et al.] // Ecosystems Without Borders 2024: Economic Systems and Processes. EcoSyst 2024. – Cham : Springer. – DOI: [10.1007/978-3-031-97876-0_23](https://doi.org/10.1007/978-3-031-97876-0_23).
15. Predicting Stock Market Movements Using Neural Networks: Review and Applications / O. Akinrinola [et al.] // Global Scientific Journals. – 2024. – Vol. 12, no. 3. – P. 55–78.
16. Radford A., Wu J., Child R. Language Models are Few-Shot Learners // Advances in Neural Information Processing Systems. – 2020. – No. 33. – P. 1877–1901.