

<https://doi.org/10.21869/2223-1536-2026-16-1-132-147>



УДК 004.891.2

Разработка многоуровневой системы для прогнозирования стоимости акций компаний в условиях высоковолатильного рынка России

А. А. Положенцев¹, А. В. Малышев¹✉, А. В. Брежнев²

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

² Российский экономический университет имени Г. В. Плеханова
Стремянный пер., д. 36, г. Москва 115054, Российская Федерация

✉ e-mail: alta76@yandex.ru

Резюме

Цель исследования – разработка гибридной модели прогнозирования стоимости акций на Московской бирже, учитывающая специфику русскоязычных новостей и интеграцию сигналов временных рядов с семантическим анализом текстов. Модель направлена на повышение точности предсказаний в условиях высокой волатильности российского финансового рынка и структурных изменений после 2022 года.

Методы. Разработана трёхуровневая модель предсказания стоимости акций. На каждом уровне предусмотрен выбор инструмента с учётом горизонта прогнозирования. Краткосрочный уровень основан на реализации рекуррентной сети GRU, показывающий высокую эффективность в период низкой волатильности. Среднечастотный уровень использует регрессионную модель с функцией потерь Хьюбера и модифицированные метрики тональности CIS для перевода новостного влияния в денежный эквивалент. Это позволяет совместить краткосрочные и фундаментальные индикаторы, повышает адаптивность модели в периоды высокой волатильности. Редкочастотный уровень объединяет статистическую модель ARIMAX, нейросетевую LSTM, а также индикаторы среднечастотного уровня для оценки долгосрочных тенденций и коррекции ошибок нижних уровней. Интеграция уровней реализована через механизм динамического перераспределения весов и межуровневую коррекцию доверительных коэффициентов.

Результаты. Разработана многоуровневая система для прогнозирования фондового рынка, реализующего гибридную архитектуру, объединяющую анализ временных рядов, фундаментальных показателей и новостного контекста с использованием языка программирования Python. Проведённая симуляция показала устойчивую точность прогнозов: в условиях рыночной турбулентности уровни L2 и L3 демонстрируют среднюю абсолютную ошибку не более 0,5 руб., что существенно ниже показателей технического уровня L1. Динамический механизм перераспределения весов между уровнями обеспечил адаптацию модели к резким изменениям рыночной конъюнктуры.

Заключение. Предложенная модель позволяет учитывать специфику российского рынка и снижает влияние рыночных шоков. Система пригодна для применения в инвестиционной аналитике и автоматизированных торговых решениях, открывая перспективы для дальнейшей адаптации под другие развивающиеся рынки.

Ключевые слова: прогнозирование фондового рынка; гибридная модель; временные ряды; нейросетевые модели; анализ новостей.

Конфликт интересов: Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

Для цитирования: Положенцев А. А., Малышев А. В., Брежнев А. В. Разработка многоуровневой системы для прогнозирования стоимости акций компаний в условиях высоковолатильного рынка России // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2026. Т. 16, № 1. С. 132–147. [https://doi.org/ 10.21869/2223-1536-2026-16-1-132-147](https://doi.org/10.21869/2223-1536-2026-16-1-132-147)

Поступила в редакцию 15.01.2026

Подписана в печать 12.01.2026

Опубликована 31.03.2026

Development of a multi-level system for forecasting stock prices of companies in the conditions of the highly volatile russian market

Alexey A. Polozhentsev¹, Alexander V. Malyshev¹ ✉, Alexey V. Brezhnev²

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

² Plekhanov Russian University of Economics
36 Stremyanny side-street, Moscow 115054, Russian Federation

✉ e-mail: alta76@yandex.ru

Abstract

The purpose of the research is to develop and formalize a hybrid model for forecasting stock prices on the Moscow Exchange, which takes into account the specifics of linguistic analysis of Russian-language news and the integration of time series signals with semantic text analysis. The model is aimed at improving prediction accuracy in the conditions of high volatility of the Russian financial market and structural changes after 2022.

Methods. A three-level model for stock price prediction has been developed. Each level implies the use of a more suitable tool considering the forecasting horizon. Thus, the short-term level is based on a GRU recurrent network and uses a sliding window, which shows high efficiency during periods of low volatility. The medium-frequency level uses a regression model with a Huber loss function and modified CIS tone metrics to translate news influence into a monetary equivalent, which allows combining short-term and fundamental indicators; the use of the latter increases the model's adaptability during periods of high volatility. The low-frequency level combines the ARIMAX statistical model, the LSTM neural network, as well as medium-frequency level indicators to assess long-term trends and correct errors of the lower levels. The integration of the levels is implemented through a mechanism of dynamic weight redistribution and inter-level adjustment of confidence coefficients.

Results. A software complex for stock market forecasting was developed based on the Python programming language, implementing a hybrid architecture that integrates time series analysis, fundamental indicators, and news context. The simulation demonstrated sustained forecasting accuracy: under market turbulence conditions, levels L2 and L3 showed a mean absolute error not exceeding 0.5 rubles, which is significantly lower than the metrics of the technical level L1. The dynamic weight redistribution mechanism between levels ensured the model's adaptation to sharp changes in market conditions.

Conclusion. The proposed hybrid forecasting architecture combines machine learning, NLP, and econometric methods, ensuring a balance between sensitivity to short-term changes and the robustness of long-term forecasts. The integration of news analysis, time series, and macroeconomic factors allows for considering the specifics of the Russian market and reduces the impact of market shocks. The system is suitable for use in investment analytics and automated trading solutions, opening prospects for further adaptation to other emerging markets.

Keywords: stock market forecasting; hybrid model; time series; neural network models; news analysis.

Conflict of interest: The Authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Polozhentsev A.A., Malyshev A.V., Brezhnev A.V. Development of a multi-level system for forecasting stock prices of companies in the conditions of the highly volatile russian market. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2026;16(1):132–147. (In Russ.) <https://doi.org/10.21869/2223-1536-2026-16-1-132-147>

Received 15.01.2026

Accepted 12.01.2026

Published 31.03.2026

Введение

Точное прогнозирование цен на акции критически важно в условиях нестабильности финансовых рынков, особенно в развивающихся экономиках, подобных России. Перспективным направлением является создание гибридных моделей, сочетающих анализ временных рядов и методов естественно-языковых вычислений (NLP) [1].

Целью работы является формализация и реализация гибридной модели прогноза для МОЕХ, учитывающей специфику лингвистического анализа русскоязычных новостей, интеграцию сигналов временных рядов с семантическим анализом текстов, разработку весовых метрик влияния информационных сообщений.

Задачи включают: модификацию моделей тонального анализа для русского языка, построение мультифакторной модели и оценку её эффективности на исторических данных.

Новизна предлагаемого подхода заключается в построении многоуровневой системы оценки новостей, основанной на адаптированной для русско-

го языка модели тональности, автоматическом выделении финансовых событий с классификацией по весу, учете индустриальной релевантности и временного затухания влияния информации.

Актуальность работы подчеркивается структурными изменениями российского рынка после 2022 г., такими как снижение ликвидности, рост роли господдержки и высокая волатильность.

Материалы и методы

Система прогнозирования фондовых акций реализована в виде трёхуровневой гибридной архитектуры, где каждый уровень отвечает за свой временной горизонт и тип данных – от высокочастотных рыночных сигналов до долгосрочных макроэкономических факторов (рис. 1). Такой подход обеспечивает сочетание реактивности, стабильности и интерпретируемости итоговых прогнозов [2].

Уровень L1 – высокочастотный технический прогноз. Реагирует на мгновенные колебания рынка, используя котировки, объёмы торгов, техниче-

ские индикаторы (RSI, MACD, SMA, ATR) и волатильность. Обновляет прогноз каждую минуту, обеспечивая адаптацию к изменениям ликвидности и настроений инвесторов [3].

Математическая архитектура. В основе уровня [4] – рекуррентная нейронная сеть GRU со скользящим окном [5]. Каждый новый бар данных x_t нормализуется локально по окну длиной W :

$$u_t^{(norm)} = \frac{u_t - \mu_{t-1}^{(W)}(u)}{\sigma_{t-1}^{(W)}(u) + \varepsilon}, \mu_{t-1}^{(W)}(u) = \frac{1}{W} \sum_{k=t-W}^{t-1} u_k, \sigma_{t-1}^{(W)}(u) = \sqrt{\frac{1}{W} \sum_{k=t-W}^{t-1} (u_k - \mu_{t-1}^{(W)}(u))^2}. \quad (1)$$

	 Уровень L1: Высокочастотный	 Уровень L2: Фундаментально-новостной	 Уровень L3: Стратегический-макро
Цель	Реагировать на колебания рынка	Захватывать среднесрочные тренды	Установить долгосрочную ценовую траекторию
Используемые данные	Котировки, объёмы, технические индикаторы	Экономические сектора, новостной сентимент, рыночные индикаторы	Макро тренды, ошибки предыдущего уровня
Временной горизонт	Минуты	Минуты до часов	Часы до дней
Математическая архитектура	Рекуррентная нейронная сеть GRU	Регрессия с потерей Хубера	Компоненты ARIMAX, LSTM, EXOG
Тип прогноза	Относительное изменение цены	Цена на основе признаков	Долгосрочный прогноз цены
Взвешивание	Адаптивное на основе корреляции	Адаптивное на основе саморегуляции	Веса комбинированной модели
Влияние новостей	—	Индекс новостей СНГ	Индекс новостей СНГ

Рис. 1. Устройство и основные характеристики каждого уровня гибридной модели

Fig. 1. Structure and main characteristics of each level of the hybrid model

Входной вектор включает в себя различные нормализованные индикаторы [6], такие как доходность, объём, спред, волатильность:

$$x_t = \begin{bmatrix} r_t^{(norm)} \\ v_t^{(norm)} \\ s_t^{(norm)} \\ \sigma_t^{(norm)} \end{bmatrix}, \quad (2)$$

где r – доходность; v – объём; s – спред; σ – волатильность.

Математическая модель процесса обновления внутреннего состояния GRU на каждом временном шаге t описывается следующей системой уравнений:

$$\begin{aligned} z_t &= \sigma(W_z x_t + U_z h_{t-1} + b_z), \\ r_t &= \sigma(W_r x_t + U_r h_{t-1} + b_r), \\ \tilde{h}_t &= \tan h(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h), \\ h_t &= (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t. \end{aligned} \quad (3)$$

Для трансформации конечного скрытого состояния h_t в непосредственно прогнозируемое значение используется полносвязный выходной слой:

$$\begin{aligned} \Delta p_t^{(fast)} &= W_y h_t + b_y, P_t^{fast} = \\ &= P_{t-1} \left(1 + \Delta p_t^{(fast)} \right). \end{aligned} \quad (4)$$

Для динамической оценки надежности прогнозов краткосрочного уровня в условиях меняющейся рыночной во-

латильности введен адаптивный вес доверия ω_t^{L1} , который рекуррентно обновляется по формуле экспоненциального сглаживания:

$$\omega_t^{L1} = \lambda \omega_{t-1}^{L1} + (1 - \lambda) \text{corr}(P_{t-\tau:t-1}^{fast}, P_{t-\tau:t-1}^{obs}), \quad (5)$$

где $\lambda \in (0,1)$ – коэффициент сглаживания; $\text{corr}(\cdot)$ – корреляция Пирсона.

Уровень L2 – фундаментально-новостной прогноз. Отвечает за среднесрочные тенденции, объединяя экономические сектора, новостную тональность и рыночные индикаторы. L2 связывает микро- и макрофакторы, оценивая, как события влияют на цену актива.

Математическая архитектура. Регрессионная модель с устойчивой функцией потерь Хубера, обновляемая методом адаптивного градиентного шага [7]:

$$\hat{P}_t = \varphi_t^T \theta_{t-1} + \beta_{t-1} g(CIS_t), \quad (6)$$

где $\varphi_t \in \mathbb{R}^p$ – вектор признаков (по секторам экономики (рис. 2)); θ_{t-1} – параметры модели; β – чувствительность к новостному индексу CIS.

Для обеспечения устойчивости модели к выбросам, характерным для периодов высокой волатильности, минимизируется функция потерь Хубера [8]:

$$\ell_\delta(e_t) = \begin{cases} \frac{1}{2} e_t^2, & |e_t| \leq \delta, \\ \delta \left(|e_t| - \frac{1}{2} \delta \right), & |e_t| > \delta, e_t = P_t^{obs} - \hat{P}_t. \end{cases} \quad (7)$$



Рис. 2. Предлагаемые фундаментальные индикаторы и мультипликаторы по секторам экономики

Fig. 2. Proposed fundamental indicators and multipliers by economic sector

Обновление параметров модели θ осуществляется методом адаптивного градиентного спуска:

$$\begin{aligned} g_t &= -\nabla_{\theta} \ell_{\delta}(e_t), \\ s_t &= \rho s_{t-1} + (1 - \rho) g_t^{\odot 2}, \\ \theta_t &= \theta_{t-1} + \eta \frac{g_t}{\sqrt{s_t + \varepsilon}}, \end{aligned} \quad (8)$$

где $\eta = 0,001$ может меняться моделью; $\rho = 0,9$ (может меняться моделью).

Для перевода семантической информации в количественную метрику ценового воздействия разработан новостной индекс CIS (Currency Impact Score):

$$CIS_{RUB} = \kappa \cdot Impact_{cluster} \cdot \frac{\sigma \cdot P}{\sqrt{L}}, \quad (9)$$

где σ – волатильность; P – цена; L – ликвидность; $\kappa = 0,5-1,5$.

Воздействие новостного кластера вычисляется по следующим формулам:

$$\begin{aligned} Tonicity &= \\ &= w_{pos} Score_{pos} - w_{neg} Score_{neg}, \\ Impact_{cluster} &= \\ &= Tonicity \sum_i Weight_{source,i}. \end{aligned} \quad (10)$$

Таким образом, уровень L2 обеспечивает интеграцию экономических признаков, семантического анализа новостей и рыночной ликвидности в единую прогнозную систему, адаптивно корректирующую параметры в условиях изменяющейся волатильности.

Уровень L3 – стратегический и макроэкономический прогноз. Формирует долгосрочную траекторию цен. L3 оценивает макротенденции [9], корректирует ошибки предыдущих уровней и выполняет роль регулятора системы.

Математическая архитектура. Комбинированная модель, включающая статистические (ARIMAX) [10] и нейросетевые (LSTM) [11] компоненты:

$$\begin{aligned} P_t^{L3} &= w_{AR,t} P_t^{ARIMAX} + \\ &+ w_{LSTM,t} P_t^{LSTM} + w_{CIS,t} CIS_t^{RUB} + \\ &+ w_{EX,t} P_t^{EXOG}, \sum w_i = 1, \end{aligned} \quad (11)$$

где

$$\begin{aligned} P_t^{ARIMAX} &= \mu + \sum_{i=1}^p \varphi_i (P_{t-i} - \mu) + \\ &+ \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{k=1}^m \beta_k X_{t,k}^{(exo)}, \end{aligned} \quad (12)$$

$$P_t^{LSTM} = f_{\theta} (P_{t-l:t-1}, X_{t-l:t}^{(exo)}). \quad (13)$$

$$\begin{aligned} P_t^{EXOG} &= \delta_{DCF} P_t^{DCF} + \\ &+ \delta_{MUL} P_t^{MUL} + \delta_{MACRO} P_t^{MACRO} + \\ &+ \delta_{CIS} CIS_t^{RUB}. \end{aligned} \quad (14)$$

EXOG-блок агрегирует фундаментальные, мультипликативные и макроэкономические оценки. Разберём компоненты этого блока подробнее. Новостной индекс CIS_t^{RUB} рассчитывается по модифицированной формуле (9) с увеличенным временным горизонтом для учета долгосрочного влияния информационного фона.

Модифицированная модель дисконтированных денежных потоков (DCF) учитывает отклонения [12] от базовых прогнозов через гиперболические трансформации фундаментальных показателей:

$$\begin{aligned} P_t^{DCF,adj} &= \\ &= \frac{\sum_{k=1}^n \frac{FCF_{t+k}^{base} (1 + \sum_j \omega_j \tan h(\alpha_j z_{j,t}))}{(1+r)^k} + \frac{FCF_{t+n}^{base} (1+g)}{(r-g)} (1 + \sum_j \varphi_j z_{j,t}^{(exit)})}{N_{shares}}, \end{aligned} \quad (15)$$

где $z_{j,t}$ – нормализованный фундаментальный показатель по сектору.

Оценка на основе сравнительного анализа мультипликаторов:

$$P_t^{MUL} = \frac{1}{m} \sum_{j=1}^m \frac{M_j^{sector}}{M_j^{company}} \cdot P_t, \quad (16)$$

где M_j – мультипликатор согласно сектору экономики (рис. 2).

Модель макроэкономической чувствительности:

$$P_t^{MACRO} = P_{t-1} \cdot \left(1 + \sum_{i=1}^n \beta_i ind_i \right), \quad (17)$$

где β_i – чувствительность акции к этим факторам (оценивается регрессией по историческим данным); ind_i – внешний фактор, имеющий значительный вес согласно сектору экономики.

Уровень L3 реализует адаптивную систему перераспределения весов между компонентами модели на основе ретроспективного анализа ошибок прогнозирования.

$$k_{bias,t} = 1 - \eta \frac{P_t^{L2} - P_t^{obs}}{P_t^{obs}},$$

$$k_{trust,t} = \tan h \left(\rho \text{corr}(P_{t-\tau:t}^{L1}, P_{t-\tau:t}^{obs}) \right), \quad (18)$$

где $k_{bias,t}$ – коэффициент коррекции смещения уровня L2; $k_{trust,t}$ – коэффициент доверия к уровню L1; η – скорость адаптации ($0 < \eta < 1$); ρ – параметр масштабирования корреляции.

Динамическое перераспределение весов осуществляется по следующим формулам:

$$w_{i,t+1} = \frac{k_{bias,t} w_{i,t}}{\sum_j k_{bias,t} w_{j,t}},$$

$$\alpha_{1,t+1} = \frac{k_{trust,t} \alpha_{1,t}}{k_{trust,t} (\alpha_{1,t} + \alpha_{2,t} + \alpha_{3,t})}, \quad (19)$$

где $w_{i,t}$ – весовые коэффициенты компонент EXOG-блока; $\alpha_{1,t}$ – веса уровней прогнозирования.

Многоуровневая архитектура системы обеспечивает постоянное взаимодействие между компонентами [13]. Уровень L2 поставляет на уровень L3 фундаментальные показатели и новостные индикаторы, формируя основу для стратегической оценки. В ответ уровень L3 динамически корректирует весовые коэффициенты уровней L2 и L1, учитывая рыночные тренды и ошибки прогнозирования. Завершающим этапом становится интеграция всех факторов на уровне L3, где объединяются стратегические, фундаментальные и технические компоненты. Такой механизм позволяет инвестору получать сбалансированную оценку, одновременно учитывающую краткосрочные рыночные колебания и долгосрочную фундаментальную устойчивость компании, что особенно ценно в условиях высокой волатильности российского рынка. Так инвестор получает оценку, учитывающую как текущие колебания [14], так и долгосрочную устойчивость компании [15].

Теоретическое обоснование многоуровневой архитектуры требует моделирования для подтверждения ранее выдвинутых гипотез. Для демонстрации реальной эффективности предложенного подхода рассмотрим поведение уровней L1, L2 и L3 в контролируемом сценарии, имитирующем переход от стабильного рынка к периоду высокой

волатильности на МОЕХ¹. Такой эксперимент позволяет наглядно проанализировать, как разные временные горизонты прогнозирования реагируют на резкие изменения рыночной ситуации.

Сценарий эксперимента:

1. Фаза 1 (0-60 минут): спокойный рынок с типичными флуктуациями и стабильным трендом.

2. Фаза 2 (60-120 минут): рыночный шок – резкое изменение цен с повышенной волатильностью.

Ожидаемое поведение уровней. В таких условиях уровни L2 и L3 должны демонстрировать принципиальное преимущество перед быстрым L1. Уровень L1, ориентированный на краткосрочные паттерны, в фазе шока обязан начать «преследовать» цену, генерируя запаз-

дывающие прогнозы с нарастающей ошибкой. В то же время L2, учитывающий фундаментальные факторы и новостной фон, должен быстрее адаптироваться к новым условиям, а уровень L3 обеспечивать стабилизацию за счет долгосрочных ориентиров.

Допущения и методика:

– L1 – высокочастотный уровень, поток рыночных данных;

– L2 – среднесрочный уровень, регрессионная модель с минимизацией потерь;

– L3 – стратегический (ARIMAX/LSTM + долгосрочный EXOG/CIS).

Рассмотрим сводные результаты эксперимента по прогнозу стоимости акции в условиях низкой и высокой волатильности (табл. 1).

Таблица 1. Сводные результаты эксперимента по прогнозу стоимости акции в условиях низкой и высокой волатильности

Table 1. Summary of experimental results on stock price forecasting under low and high volatility conditions

Мин	L1 (P)	L2 (P)	L3 (P)	P^{obs} (P)	MAE_{L1}	MAE_{L2}	MAE_{L3}	$corr_{L1}^{Pearson}$	$corr_{L1}^{Win 5}$
0	—	—	—	293,000	—	—	—	—	—
1	292,663	—	—	292,700	0,037	—	—	—	—
2	292,524	—	—	292,500	0,024	—	—	—	—
3	292,666	—	—	292,700	0,034	—	—	0,688	0,688
4	293,109	—	—	293,100	0,009	—	—	0,499	0,499
5	293,301	—	—	293,300	0,001	—	—	0,787	0,787
15	293,900	294,12	—	293,900	0,000	0,220	—	0,891	0,120
30	294,500	294,41	—	294,500	0,000	0,090	—	0,964	0,050
45	294,950	294,92	—	294,950	0,000	0,030	—	0,984	0,020
60	295,400	295,16	295,689	295,400	0,000	0,240	0,289	0,992	0,010
75	295,800	291,00	—	289,000	6,800	2,000	—	0,900	–0,80
90	295,500	287,50	—	287,000	8,500	0,500	—	0,870	–0,95
105	295,000	286,00	—	286,000	9,000	0,000	—	0,880	–0,98
120	294,000	285,20	285,505	285,000	9,000	0,200	0,505	0,910	–0,60

Примечание. MAE_* – модуль ошибки модели в этой точке ($|P_{L*} - P_{obs}|$); $corr_{L1}^{Pearson}$ – корреляция Пирсона между всеми парами (P^{fast}, P^{obs}) от 0 до $t - 1$. Она остаётся высокой после шока, потому что содержит много предшествующих «спокойных» точек, где L1 идеально соответствовал; $corr_{L1}^{Win 5}$ – корреляция по локальному окну размером в 5 предыдущих значений.

¹ Московская биржа. URL: [https:// www.moex.com/](https://www.moex.com/) (дата обращения: 17.12.2025).

Для демонстрации работы многоуровневой модели рассмотрим последовательность расчётов на временном интервале $t = 0,60$.

На первом уровне (L1) выполняется высокочастотный прогноз на основе нормализованных рыночных признаков: доходности (ret_{norm}), волатильности (vol_{norm}) и спреда ($spread_{norm}$).

Первый временной шаг:

$$(t = 0 \rightarrow t = 1).$$

На основе нормализованных признаков:

$$ret_{norm} = -0,78, vol_{norm} = 0,62, \\ spread_{norm} = 0,71$$

рассчитывается относительное изменение цены:

$$\Delta p_{L1,1} = 0,0020 \cdot (-0,78) + \\ + 0,0010 \cdot 0,62 - 0,0010 \cdot 0,71 + \\ + 0,0005 = -0,00115.$$

Перевод в рубли:

$$\Delta P_0 = 293,00 \cdot (-0,00115) = \\ = -0,337 \text{ руб.}$$

Новое предсказание:

$$P_1^{fast} = 293,00 - 0,337 = \\ = 292,663 \text{ руб.} \approx 292,66.$$

Второй временной шаг:

$$(t = 1 \rightarrow t = 2)$$

отражает адаптацию модели при изменении рыночных признаков:

$$ret_{norm} = -0,45, vol_{norm} = 0,30, \\ spread_{norm} = 0,50.$$

Расчёт:

$$\Delta p_{L1,2} = 0,0020 \cdot (-0,45) + \\ + 0,0010 \cdot 0,30 - 0,0010 \cdot 0,50 + \\ + 0,0005 = -0,00060,$$

$$\Delta P_1 = 292,70 \times \\ \times (-0,00060) = -0,1756 \text{ руб.}, \\ P_2^{fast} = 292,70 - 0,176 = 292,524 \text{ руб.}$$

На втором уровне (L2) применяется регрессионная модель с функцией потерь Хубера, использующая фундаментальные признаки и индекс новостной тональности (CIS).

Для $t = 15$:

$$\theta_0 = \left[P_{t-1}^{obs}, \omega_{ROE}, \omega_{BVPS}, \dots, \omega_{\frac{P}{Deposits}} \right] = \\ = [293,85, 0,001, 0,001, \dots, 0,001],$$

$$\beta_0 = 0,05, \varphi_0 = \\ = [1, 0,010, 0,008, \dots, 0,100], CIS_0 = \\ = 0, s_0 = 10^{-6}.$$

$$\hat{P}^t = 293,85 + 0,001 \cdot 0,01 + \\ + \dots + 0,001 \cdot 0,1 + \\ + 0,05 \cdot 0 \approx 294,12 \text{ руб.},$$

$$e_t = y - \hat{P}^t = \\ = 293,90 - 294,12 = 0,22 \text{ руб.}$$

Так как $|e_t| < \delta = 0,5$, используется квадратичная часть потери Хьюбера:

$$g_t = e_t \cdot \varphi_t = \\ = 0,22 \cdot [1, 0,010, 0,008, \dots, 0,100] = \\ = [0,22, 0,0022, 0,00176, \dots, 0,022]. \\ s_t = \rho s_{t-1} + (1 - \rho) g_t^{\odot 2},$$

$$g_t^{\odot 2} \approx [0,0484, 4,84 \cdot 10^{-6}, 3,10 \cdot 10^{-6}, \dots, 0,000484], \\ s_t \approx 0,9 \cdot 10^{-6} + 0,1 \cdot [0,0484, \dots] = [0,0048409, 5,74 \cdot 10^{-6}, \dots, 4,849 \cdot 10^{-4}].$$

Формула обновления параметров:

$$\theta_t = \theta_{t-1} + \eta \frac{g_t}{\sqrt{s_t + \varepsilon}}.$$

После вычисления $\sqrt{s_t}$ и нормализации

$$\frac{g_t}{\sqrt{s_t}} \approx [3,162, 3,162, 3,162, 3,162, 3,162],$$

$$\Delta\theta = 0,001 \cdot \frac{g_t}{\sqrt{s_t}} = [0,003162, \dots],$$

$$\theta_t = \theta_{t-1} +$$

$$+ \Delta\theta \approx [293,853162, 0,013162, \dots].$$

На третьем уровне (L3) объединяются результаты ARIMAX-, LSTM-, CIS- и EXOG-блоков для построения интегрированного прогноза:

$$P_{60}^{DCF} = 295 \cdot 1 + 0,3 \cdot 0 + 0,25 \cdot 0 + 0,2 \cdot 0 - 0,25 \cdot 0 = 295.$$

$$P_{60}^{MACRO} = 295 \cdot 1 + 0,4 \cdot \Delta \text{ставка} - 0,3 \cdot \Delta \text{ликвидность} = 295,00 \text{ руб.}$$

$$P_{60}^{EXOG} = 0,4 \cdot 295 + 0,3 \cdot 295 + 0,2 \cdot 295 + 0,1 \cdot 295,6 = 295,06 \text{ руб.}$$

$$MAE_{AR} = 0,015, MAE_{LSTM} = 0,010, MAE_{CIS} = 0,080, MAE_{EXOG} = 0,030.$$

$$P_{60}^{ARIMAX} = 295,90, P_{60}^{LSTM} = 295,90.$$

$$\tilde{w}_i = e^{-\beta \cdot MAE_i} \Rightarrow \tilde{w}_{AR} = 0,687, \tilde{w}_{LSTM} = 0,778, \tilde{w}_{CIS} = 0,135, \tilde{w}_{EXOG} = 0,472.$$

$$\sum \tilde{w} = 2,072 \Rightarrow w_{AR} = 0,332, w_{LSTM} = 0,375, w_{CIS} = 0,065, w_{EXOG} = 0,228.$$

$$P_{60}^{L3} = 0,332 \cdot 295,9 + 0,375 \cdot 295,9 + 0,065 \cdot 295,6 + 0,228 \cdot 295,06.$$

$$P_{60}^{L3} = 98,27 + 110,85 + 19,50 + 67,38 = 295,69 \text{ руб.}$$

Итоговый прогноз уровня L3 стабилизирует результат нижних уровней и отражает совокупное влияние макро- и фундаментальных факторов.

Результаты и их обсуждение

1. Поведение уровней в момент рыночного шока. В момент информационного шока на 75-й минуте наблюдалось резкое падение наблюдаемой цены P_{obs} с 295,4 до 289,0 руб. Уровень L1, основанный на технических индикаторах, продемонстрировал инерционное поведение и выдал прогноз 295,8 руб. ($MAE = 6,8$ руб.), в то время как L2, интегрирующий новостные и ордерные данные, быстро скорректировал значение до 291,0 руб. ($MAE = 2,0$ руб.). Это подтверждает, что L2 способен быстрее

адаптироваться к новым рыночным условиям, тогда как L1 имеет лаг из-за ориентации на краткосрочные паттерны без учёта контекста.

2. Изменение корреляционных метрик. После возникновения шока глобальная корреляция L1 оставалась высокой ($\sim 0,9$), но оконная корреляция снизилась до $-0,8$. Такое расхождение показывает, что традиционные метрики могут вводить в заблуждение в периоды нестабильности. Анализ локальных метрик позволяет своевременно фиксировать деградацию модели [16] и инициировать перераспределение доверительных весов между уровнями, что является важным элементом адаптивной архитектуры системы [17].

3. Динамика ошибок на интервале 90–120 минут. При дальнейшем снижении цены с 287 до 285 руб. уровень L1 медленно снижал прогноз, сохраняя высокие ошибки ($MAE = 8,5\text{--}9,0$ руб.). В то же время уровень L2 обеспечил точность до $MAE \leq 0,5$ руб., а стратегический уровень L3 после пересчёта выдал прогноз 285,5 руб. с $MAE = 0,5$ руб. Это подтверждает, что L3 выполняет стабилизирующую функцию, компенсируя ошибки нижних уровней и обеспечивая устойчивость модели при волатильных изменениях рынка.

4. Подтверждение гипотез о распределении функций уровней. Полученные данные подтвердили все выдвинутые гипотезы. Уровень L1 обеспечивает чувствительность и мгновенную реакцию, L2 – быструю адаптацию к новостным и поведенческим изменениям рынка, а L3 – долгосрочную стабилизацию и контроль распределения весов. Такое распределение ролей обеспечивает баланс между реактивностью и устойчивостью, делая систему надёжной как в спокойных, так и в стрессовых рыночных условиях [18].

5. Практическая интерпретация результатов. Реализация механизма динамического перераспределения доверительных коэффициентов между уровнями позволила повысить устойчивость прогноза и снизить совокупную ошибку системы. В практическом применении это означает, что архитектура способна не только реагировать на рыночные аномалии, но и самостоятельно коррек-

тировать стратегию прогнозирования в реальном времени, что делает её перспективной для использования в системах инвестиционной аналитики и алгоритмической торговли.

Выводы

В ходе проведённого эксперимента, направленного на проверку эффективности трёхуровневой гибридной архитектуры прогнозирования цен акций на MOEX, были получены результаты, подтверждающие высокую адаптивность, устойчивость и точность предложенной модели.

1. Высокая точность и адаптивность: на интервалах рыночных шоков уровни L2 и L3 продемонстрировали среднюю абсолютную ошибку (MAE) менее 1 руб., что значительно ниже, чем у базового уровня L1 (до 9 руб.). Это подтверждает способность гибридной архитектуры динамически перестраиваться под изменяющиеся рыночные условия и эффективно обрабатывать как рыночные, так и новостные сигналы.

2. Интеллектуальная интеграция сигналов: результаты показали, что комбинация временных рядов, лингвистического анализа новостей и макроэкономических индикаторов обеспечивает синергетический эффект, повышающий устойчивость прогноза [19]. В частности, L2 эффективно реагирует на новостные импульсы, а L3 корректирует стратегический тренд, снижая влияние краткосрочных искажений.

3. Стабильность и интерпретируемость: уровень L3 доказал свою роль в стабилизации итоговых прогнозов, выступая регулятором весов между подсистемами. Механизм адаптивного перераспределения доверительных коэффициентов обеспечивает сбалансированную реакцию всей модели при колебаниях рынка.

4. Практическая применимость: предложенная архитектура может быть использована в системах инвестиционной аналитики и алгоритмической торговли, где требуется высокая скорость реакции и устойчивость к информационным шокам. Структура модели, построенная на принципах распределённости и микросервисной интеграции,

также открывает возможности масштабирования для анализа различных секторов экономики.

Таким образом, результаты проведённого исследования подтверждают перспективность гибридного подхода к прогнозированию фондового рынка. Он сочетает преимущества нейросетевых, статистических и лингвистических методов, обеспечивая баланс между чувствительностью к краткосрочным изменениям и устойчивостью долгосрочных прогнозов. Дальнейшее развитие данного направления позволит повысить точность финансовых прогнозов и создать интеллектуальные системы поддержки инвестиционных решений нового поколения.

Список литературы

1. Kingma D. P., Ba J. L. Adam: A Method for Stochastic Optimization // Proceedings of the 3rd International Conference for Learning Representations (ICLR). URL: <https://arxiv.org/abs/1412.6980> (дата обращения: 17.12.2025).
2. Time Series Analysis: Forecasting and Control / G. E. P. Box, G. M. Jenkins, G. C. Reinsel, G. M. Ljung. 5th ed. Hoboken: John Wiley & Sons, 2015. 712 p.
3. Fama E. F., French K. R. A Five-Factor Asset Pricing Model // Journal of Financial Economics. 2015. Vol. 116, N 1. P. 1–22.
4. Hinton G. E., Srivastava N., Krizhevsky A., Sutskever I., Salakhutdinov R. Improving Neural Networks by Preventing Co-adaptation of Feature Detectors // Neural and Evolutionary Computing. URL: <https://arxiv.org/abs/1207.0580v1> (дата обращения: 17.12.2025).
5. Белоусов А. В. Методы анализа временных рядов в экономике. М.: Финансы и статистика, 2018. 312 с.
6. Шамраева В. В. Математические методы прогнозирования изменения цены акций и их реализация методами машинного обучения // Фундаментальные исследования. 2024. № 11. С. 88–96.
7. Васильев А., Смирнов И. Применение машинного обучения для прогнозирования фондового рынка России // Computational Economics and Finance Journal. 2023. Т. 5, № 2. С. 34–45.

8. Huber P. J. Robust Estimation of a Location Parameter // *The Annals of Mathematical Statistics*. 1964. Vol. 35, N 1. P. 73–101.
9. Сентимент частных инвесторов и его влияние на доходность российских акций / Т. В. Теплова, Т. В. Соколова, А. Ф. Томтосов [и др.] // *Журнал Новой экономической ассоциации*. 2022. № 1 (53). С. 53–84.
10. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. 1997. Vol. 9, N 8. P. 1735–1780.
11. Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation / K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio // *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha, 2014. P. 1724–1734.
12. Пятибратов Д. В., Логинов А. В., Болотов Т. А. Сравнительный анализ алгоритмов машинного обучения в задачах исследования фондового рынка // *Вестник науки*. 2025. Т. 3, вып. 10 (91). С. 644–650.
13. Глебова А. Г., Ковалева А. А. Прогнозирование волатильности российского биржевого рынка акций в условиях международных санкций // *Финансы: теория и практика*. 2024. № 1. С. 20–29.
14. Tetlock P. C. Giving Content to Investor Sentiment: The Role of Media in the Stock Market // *The Journal of Finance*. 2007. Vol. 62, N 3. P. 1139–1168.
15. Damodaran A. Investment Valuation: Tools and Techniques for Determining the Value of Any Asset. 3rd ed. Hoboken: John Wiley & Sons, 2012. 992 p.
16. PyTorch: An Imperative Style, High-Performance Deep Learning Library / A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury [et al.] // *Machine Learning*. URL: <https://arxiv.org/abs/1207.0580v1> (дата обращения: 17.12.2025).
17. Scikit-learn: Machine Learning in Python / F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion [et al.] // *Journal of Machine Learning Research*. 2011. Vol. 12. P. 2825–2830.
18. Минкин В. А., Кулешов Д. А. Применение методов машинного обучения для прогнозирования фондового рынка // *Вестник Финансового университета*. 2022. № 3. С. 55–66.
19. Першина А. А., Арутюнян А. Г., Косников С. Н. Применение нейросетей в прогнозировании экономических тенденций // *Региональная и отраслевая экономика*. 2023. № 5. С. 164–171. https://doi.org/10.47576/2949-1916_2023_5_164

References

1. Kingma D.P., Ba J.L. Adam: A Method for Stochastic Optimization. In: *Proceedings of the 3rd International Conference for Learning Representations (ICLR)*. Available at: <https://arxiv.org/abs/1412.6980> (accessed 17.12.2025).

2. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. Time Series Analysis: Forecasting and Control. 5th ed. Hoboken: John Wiley & Sons; 2015. 712 p.
3. Fama E.F., French K.R. A Five-Factor Asset Pricing Model. *Journal of Financial Economics*. 2015;116(1):1–22.
4. Hinton G.E., Srivastava N., Krizhevsky A., Sutskever I., Salakhutdinov R. Improving Neural Networks by Preventing Co-adaptation of Feature Detectors. In: Neural and Evolutionary Computing. Available at: <https://arxiv.org/abs/1207.0580v1> (accessed 17.12.2025).
5. Belousov A.V. Methods of Time Series Analysis in Economics. Moscow: Finansy i statistika; 2018. 312 p. (In Russ.)
6. Shamraeva V.V. Mathematical Methods for Forecasting Stock Price Changes and Their Implementation Using Machine Learning. *Fundamental'nye issledovaniya = Fundamental Research*. 2024;(11):88-96. (In Russ.)
7. Vasiliev A., Smirnov I. Application of Machine Learning for Forecasting the Russian Stock Market. *Computational Economics and Finance Journal*. 2023;5(2):34–45. (In Russ.)
8. Huber P.J. Robust Estimation of a Location Parameter. *The Annals of Mathematical Statistics*. 1964;35(1):73–101.
9. Teplova T.V., Sokolova T.V., Tomtosov A.F., et al. Sentiment of Private Investors and Its Impact on the Returns of Russian Stocks. *Zhurnal Novoi ekonomicheskoi assotsiatsii = Journal of the New Economic Association*. 2022;(1):53–84. (In Russ.)
10. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*. 1997;9(8):1735–1780.
11. Cho K., van Merriënboer B., Gulcehre C., Bahdanau D., Bougares F., Schwenk H., Bengio Y. Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. In: *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha; 2014. P. 1724–1734.
12. Pyatibratov D.V., Loginov A.V., Bolotov T.A. Comparative Analysis of Machine Learning Algorithms in Stock Market Research Tasks. *Vestnik nauki = Science Bulletin*. 2025;3:644-650. (In Russ.)
14. Tetlock P. C. Giving Content to Investor Sentiment: The Role of Media in the Stock Market. *The Journal of Finance*. 2007;62(3):1139–1168.
13. Glebova A.G., Kovaleva A.A. Forecasting the Volatility of the Russian Stock Market under International Sanctions. *Finansy: teoriya i praktika = Finance: Theory and Practice*. 2024;(1):20–29. (In Russ.)
15. Damodaran A. Investment Valuation: Tools and Techniques for Determining the Value of Any Asset. 3rd ed. Hoboken: John Wiley & Sons; 2012. 992 p.
16. Paszke A., Gross S., Massa F., Lerer A., Bradbury J. et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library. In: Machine Learning. Available at: <https://arxiv.org/abs/1207.0580v1> (accessed 17.12.2025).

17. Pedregosa F., Varoquaux G., Gramfort A., Michel V., Thirion B., et al. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011;12:2825–2830.

18. Minkin V.A., Kuleshov D.A. Application of Machine Learning Methods for Stock Market Forecasting. *Vestnik Finansovogo universiteta = Bulletin of the Financial University*. 2022;(3):55–66. (In Russ.)

19. Pershina A.A., Arutyunyan A.G., Kosnikov S.N. Application of neural networks in forecasting economic trends. *Regional'naya i otraslevaya ekonomika = Regional and Sectoral Economics*. 2023;(5):164-171. (In Russ.) https://doi.org/10.47576/2949-1916_2023_5_164

Информация об авторах / Information about the Authors

Положенцев Алексей Анатольевич, магистрант кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: polojencev135@mail.ru, ORCID: 0009-0004-6824-1019

Alexey A. Polozhentsev, Undergraduate at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation, e-mail: polojencev135@mail.ru, ORCID: 0009-0004-6824-1019

Малышев Александр Васильевич, кандидат технических наук, доцент кафедры программной инженерии, Юго-Западный государственный университет, г. Курск, Российская Федерация, e-mail: alta76@yandex.ru, ORCID: 0000-0002-9938-3456

Alexander V. Malyshev, Candidate of Sciences (Engineering), Associate Professor at the Department of Software Engineering, Southwest State University, Kursk, Russian Federation, e-mail: alta76@yandex.ru, ORCID: 0000-0002-9938-3456

Брежнев Алексей Викторович, кандидат технических наук, доцент, Российский экономический университет имени Г. В. Плеханова, г. Москва, Российская Федерация, e-mail: brezhnev.av@rea.ru, ORCID: 0000-0002-3679-7379

Alexey V. Brezhnev, Candidate of Sciences (Engineering), Associate Professor, Plekhanov Russian University of Economics, Moscow, Russian Federation, e-mail: brezhnev.av@rea.ru, ORCID: 0000-0002-3679-7379