

ПРОГНОЗИРОВАНИЕ ВРЕМЕННЫХ РЯДОВ С ПОМОЩЬЮ РЕКУРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ

А. Э. Зеляев

Ульяновский государственный университет, Россия

E-mail: persistent@bk.ru

В работе проведён сравнительный анализ эффективности рекуррентных нейронных сетей – классической RNN, LSTM и GRU – при прогнозировании финансовых временных рядов на примере цен закрытия индекса Московской биржи (IMOEX). Прогнозирование выполнялось на горизонтах 1, 5, 21, 60 и 100 торговых дней с использованием исторических данных за период с 1 января 2014 года по 1 января 2024 года. Оценка моделей осуществлялась по метрикам средней абсолютной ошибки (MAE) и среднеквадратичной ошибки (RMSE). Эксперименты показали, что GRU-модель обеспечивает наивысшую точность прогнозов среди рассмотренных архитектур. На основании полученных результатов рекомендуется применять GRU в системах поддержки принятия решений в финансовой сфере.

DECISION MAKING BASED ON THE SHARPE RATIO AND CRITERIA OF THE THEORY OF GAMES WITH NATURE

A. E. Zelyaev

The paper provides a comparative analysis of the effectiveness of recurrent neural networks – classical RNN, LSTM and GRU – in predicting financial time series using the example of the closing prices of the Moscow Stock Exchange index (IMOEX). Forecasting was performed on the horizons of 1, 5, 21, 50 and 100 trading days using historical data for the period from January 1, 2014 to January 1, 2024. The models were evaluated using the metrics of mean absolute error (MAE) and RMS error (RMSE). Experiments have shown that the GRU model provides the highest prediction accuracy among the architectures considered. Based on the results obtained, it is recommended to use GRU in decision support systems in the financial sector.

Введение. С 2020 года число частных инвесторов на Московской бирже (МОЕХ) выросло с 4 до 38 млн человек [1], что значительно усилило интерес к автоматизированным инструментам прогнозирования финансовых показателей. Значения закрытия торговых дней индекса Московской биржи являются классическим вариантом временного ряда [2]. Традиционные статистические методы зачастую оказываются недостаточно эффективными из-за высокой волатильности и сложной, нелинейной структуры финансовых временных рядов [3]. В этой связи перспективным направлением становятся рекуррентные нейронные сети (RNN), особенно их модификации – LSTM и GRU, способные улавливать долгосрочные зависимости и нелинейные закономерности во временных данных. Тем не менее, вопрос о том, какая из архитектур наиболее подходит для условий конкретного рынка, остаётся дискуссионным. В связи с этим актуальным представляется проведение сравнительного анализа производительности RNN, LSTM и GRU при прогнозировании индекса Московской биржи IMOEX. Целью данного

исследования является оценка и сопоставление эффективности указанных моделей в решении этой задачи.

Задачи исследования

- Провести анализ современных подходов к прогнозированию финансовых временных рядов.

- Реализовать и обучить модели RNN, LSTM и GRU на исторических данных цен закрытия индекса ИМОЕХ.

- Оценить точность полученных моделей с использованием метрик MAE (средняя абсолютная ошибка) и RMSE (среднеквадратичная ошибка).

- Выполнить сравнительный анализ эффективности моделей и сформулировать практические рекомендации по их применению.

Объект исследования: временной ряд цен закрытия индекса Московской биржи (ИМОЕХ).

Предмет исследования: сравнительная эффективность архитектур RNN, LSTM и GRU при решении задачи краткосрочного и среднесрочного прогнозирования финансовых временных рядов.

Особенности финансовых временных рядов

Финансовые временные ряды характеризуются рядом сложных свойств, затрудняющих их анализ [2]:

Нестационарность – статистические характеристики (например, среднее и дисперсия) со временем изменяются;

Автокорреляция – наблюдения в близкие моменты времени взаимозависимы;

Гетероскедастичность – дисперсия ряда не постоянна и может меняться во времени;

Долгосрочная зависимость («долгая память») – влияние прошлых значений сохраняется на протяжении длительного периода.

Учёт этих особенностей требует применения продвинутых методов анализа, среди которых особое место занимают рекуррентные нейронные сети (RNN), способные эффективно моделировать сложные временные зависимости.

Принципы работы рекуррентных нейронных сетей

Классические рекуррентные нейронные сети (RNN) [4] предназначены для обработки последовательных данных и основаны на передаче скрытого состояния от одного временного шага к следующему. Однако на практике они сталкиваются с проблемой затухающих (или, наоборот, взрывающихся) градиентов, что затрудняет обучение и ограничивает способность модели улавливать долгосрочные временные зависимости.

Для преодоления этих ограничений была предложена архитектура сети с долгой краткосрочной памятью (LSTM) [5]. LSTM вводит специальную ячейку памяти и три управляющих вентиля:

Вентиль забывания (forget gate) – определяет, какую информацию из предыдущего состояния памяти следует сохранить или удалить;

Вентиль обновления входа (input gate) – регулирует, какие новые данные необходимо записать в ячейку памяти;

Вентиль выхода (output gate) – контролирует, какая часть обновлённой памяти будет передана на выход.

Альтернативой LSTM выступает управляемый рекуррентный блок (GRU) [6] – упрощённая архитектура, объединяющая функции вентиля забывания и входа в единый вентиль обновления (update gate), а также вводящая вентиль сброса (reset gate), управляющий влиянием предыдущего состояния на текущее обновление. Благодаря меньшему количеству параметров GRU обучается быстрее и при ограниченных объёмах данных часто демонстрирует сопоставимую или даже более высокую точность по сравнению с LSTM.

Методология построения и оценки моделей

Источник данных. В исследовании использованы ежедневные значения цен закрытия индекса Московской биржи (IMOEX) за период с 1 января 2014 года по 1 января 2025 года, что составляет 2475 наблюдений. Данные получены из открытых источников и обработаны в облачной среде Google Colab [7] с применением языка программирования Python и следующих библиотек: Pandas, NumPy, Scikit-learn, Keras и Matplotlib.

Подготовка данных. Нормализация значений цен закрытия выполнена с помощью MinMaxScaler для приведения данных к диапазону [0, 1].

Исходный набор данных разделён на обучающую (80%) и тестовую (20%) выборки.

Для формирования входных последовательностей применён метод скользящего окна [8] с размером окна 60 торговых дней, что позволяет модели учитывать предыдущие 60 значений при прогнозировании следующего.

Метрики оценки. MAE (Mean Absolute Error) – метрика, отражающая среднюю абсолютную ошибку прогноза и обладающая высокой интерпретируемостью.

RMSE (Root Mean Squared Error) – метрика, более чувствительная к крупным отклонениям, поскольку ошибки возводятся в квадрат перед усреднением.

Результаты эксперимента

Модель	Горизонт	MAE	RMSE	Место
RNN	1 день	47.14	86.97	2
LSTM		49.08	92.39	3
GRU		39.04	72.2	1
RNN	5 дней (неделя)	89.94	149.64	2
LSTM		94.01	160.65	3
GRU		82.35	146.83	1
RNN	21 день (месяц)	188.89	271.61	3
LSTM		179.37	267.0	2
GRU		172.7	261.12	1
RNN	60 дней (квартал)	454.05	631.5	2
LSTM		441.84	644.41	2
GRU		453.35	636.63	2
RNN	100 дней	710.73	932.35	3

LSTM		659.09	863.01	1
GRU		691.04	899.42	2

Анализ подтвердил, что GRU наиболее точно воспроизводит траекторию реальных значений, особенно в условиях резких изменений волатильности. На трех из пяти интервалов (1, 5, 21) GRU показал лучший результат. На более длительных интервалах 60 и 100 дней GRU занял второе место.

Заключение. В ходе исследования было проведено сравнение трёх архитектур рекуррентных нейронных сетей – RNN, LSTM и GRU – в контексте прогнозирования финансовых временных рядов. Эксперименты показали, что модель GRU демонстрирует наилучшие результаты как с точки зрения точности прогноза, так и вычислительной эффективности. Это преимущество объясняется удачным сочетанием относительной простоты архитектуры и высокой способности модели выявлять сложные временные зависимости в данных.

Полученные результаты подтверждают целесообразность использования GRU-моделей для решения задач краткосрочного и среднесрочного прогнозирования финансовых временных рядов. В перспективе представляется перспективным расширение подхода за счёт включения экзогенных факторов – таких как макроэкономические показатели или текстовые данные из новостных источников – а также разработка гибридных моделей, сочетающих преимущества различных архитектур [8].

СПИСОК ЛИТЕРАТУРЫ

1. Розничные инвесторы с начала года вложили в ценные бумаги на Московской бирже более 1,5 трлн. рублей // Московская биржа. [Электронный ресурс]. URL: <https://www.moex.com/n93371/> (дата обращения: 29.09.2025).
2. *Hamilton J. D.* Time Series Analysis / Princeton : Princeton University Press, 1994. 799 p.
3. *Box G. E. P., Jenkins G. M., Reinsel G. C.* Time Series Analysis: Forecasting and Control / Hoboken : Wiley, 2008. 784 p.
4. *Rumelhart D. E., Hinton G. E., Williams R. J.* Learning representations by back-propagating errors // Nature. 1986. Vol. 323. № 6088. P. 533-536.
5. *Hochreiter S., Schmidhuber J.* Long Short-Term Memory // Neural Computation. 1997. Vol. 9. № 8. P. 1735-1780.
6. *Cho K., Merriënboer B., Gulcehre C. [et al.]* Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation // ARXIV. 2014. [Electronic resource]. URL: <https://arxiv.org/abs/1406.1078> (дата обращения: 29.09.2025).
7. *Рындина С. В.* Анализ данных: использование Google Colab с Google Drive и GitHub /: учеб.-метод. пособие. Пенза : Изд-во ПГУ, 2024. 44 с.
8. *Zhang G. P.* Time series forecasting using a hybrid ARIMA and neural network model // Neurocomputing. 2003. Vol. 50. P. 159-175.