

20. ФИНАНСОВОЕ ПРОГНОЗИРОВАНИЕ ПРИ ПОМОЩИ НЕЙРОСЕТЕЙ

Рушлевич И.С., Кожевников А.Д.

*Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь*

Мозоль А.А. – канд. эк. наук, доцент каф. ЭИ

Аннотация. В статье исследуется применение нейросетевых моделей (RNN, LSTM, GRU, CNN, трансформеры) для прогнозирования финансовых рынков. Рассмотрены их преимущества перед традиционными методами (ARIMA), включая способность анализировать временные зависимости и визуальные паттерны. Особое внимание уделено гибридным архитектурам (CNN-LSTM), сочетающим анализ графиков цен и временных рядов. Обсуждаются ключевые вызовы: вычислительная сложность, переобучение и обработка неструктурированных данных (новости, соцсети). Результаты подтверждают перспективность нейросетей для алгоритмического трейдинга.

Для прогнозирования финансовых рынков используются рекуррентные нейросети (RNN), сети с долговременной кратковременной памятью (LSTM) и сети с управляющими воротами (GRU). Эти модели предназначены для работы с последовательными данными и учитывают временные зависимости. Рекуррентные нейросети (RNN) обладают способностью запоминать предшествующие состояния, но имеют значительный недостаток – проблему исчезающего градиента, из-за которой предсказания на длинных временных отрезках теряют точность. Для решения этой проблемы были разработаны усовершенствованные архитектуры, такие как LSTM и GRU. LSTM-сети используют специальные механизмы управления памятью, позволяя сохранять и обрабатывать информацию о более длинных временных интервалах, что особенно полезно для анализа временных рядов цен акций и криптовалют. GRU работает аналогично LSTM, но имеет более простую структуру и меньшее количество параметров, что делает её менее требовательной к вычислительным ресурсам. Эти модели активно применяются для прогнозирования движения цен на основе исторических данных [1]. Другим важным классом нейросетей являются сверточные нейросети (CNN), которые традиционно применяются в задачах компьютерного зрения, но также находят применение в финансовой сфере. Основное преимущество сверточных сетей заключается в их способности выявлять локальные паттерны в данных, что особенно полезно при анализе графиков цен, свечных формаций и других визуальных характеристик рыночных данных. Такие модели могут автоматически обнаруживать повторяющиеся закономерности в изменении цен, что делает их ценным инструментом для алгоритмического трейдинга и технического анализа. Сверточные сети могут анализировать изображения графиков акций и выявлять характерные фигуры, такие как "голова и плечи" или "двойное дно", которые используются трейдерами для принятия решений о входе в сделки. Гибридные модели, сочетающие сверточные нейросети (CNN) и рекуррентные сети (LSTM), позволяют объединять преимущества обоих подходов. В таких моделях CNN используется для анализа графических паттернов, а LSTM – для обработки временных зависимостей, что позволяет значительно повысить точность прогнозов. Гибридная модель может сначала анализировать свечные графики с помощью CNN, выявляя ключевые визуальные паттерны, а затем передавать эту информацию в LSTM, которая учитывает историческую динамику цен и выявляет тренды на рынке [2].

Для обучения нейросетей в финансовом прогнозировании используются различные типы данных. В первую очередь, это структурированные данные, такие как временные ряды цен (Open, High, Low, Close), объемы торгов, а также различные технические индикаторы, например, RSI (индекс относительной силы), MACD (схождение и расхождение скользящих средних) и скользящие средние (SMA, EMA). Эти показатели позволяют выявлять рыночные тренды и анализировать динамику изменения цен. Активно используются неструктурированные данные, такие как новости, аналитические отчеты, посты в социальных сетях и форумы, которые можно обрабатывать с помощью методов обработки естественного языка (NLP). Анализ настроений на рынке (sentiment analysis) помогает определять, являются ли новости и публикации позитивными или негативными, что может влиять на движение цен активов. LSTM-сети широко применяются для предсказания будущих цен акций, криптовалют и других финансовых инструментов. Они могут использоваться для предсказания дневных, часовых или даже минутных цен активов. Часто такие модели сравнивают с традиционными статистическими методами, такими как ARIMA (авторегрессионная интегрированная скользящая средняя), которые также применяются для временных рядов, но имеют ограниченные возможности в случае сложных нелинейных зависимостей. Нейросетевые модели могут использоваться для

генерации торговых сигналов, классифицированные рыночные условия и определяя моменты для покупки, продажи или удержания активов. Однако существует риск переобучения, когда модель слишком сильно адаптируется к историческим данным и теряет способность обобщать новые рыночные условия. Финансовые рынки постоянно изменяются, поэтому модели требуют регулярного обновления и переобучения.

Одной из главных технических сложностей является высокая вычислительная сложность таких моделей, особенно при работе с большими объемами данных. Обучение сложных нейросетевых моделей требует значительных ресурсов, таких как мощные графические процессоры (GPU) и специализированные аппаратные ускорители (TPU).

Также необходимо учитывать сложность предварительной обработки данных, которая включает в себя очистку, нормализацию и создание обучающих выборок. Другой важной технической проблемой является необходимость регулярного переобучения моделей, поскольку финансовые рынки меняются со временем. Это требует дополнительных вычислительных мощностей и разработки стратегий адаптации моделей к изменяющимся условиям.

Кроме того, при работе с нейросетями возникает проблема «затухания градиента» в глубоких моделях, что может снижать эффективность обучения. Помимо этого, сложные нейросетевые модели требуют грамотной настройки гиперпараметров (learning rate, batch size, количество слоев и нейронов), что требует значительного опыта и экспериментов. Ошибки в конфигурации могут привести к переобучению или, наоборот, к неспособности модели находить полезные закономерности. Другая проблема связана с доступом к качественным данным, поскольку многие финансовые данные являются закрытыми и требуют покупки лицензий. Кроме того, нейросетевые модели подвержены рискам, связанным с неожиданными рыночными событиями, такими как «черные лебеди» – редкие и значимые события, которые невозможно предсказать с помощью исторических данных.

Качество прогнозов оценивалось по двум основным метрикам. Среднеквадратичная ошибка (MSE) рассчитывалась как усредненная квадратичная разница между реальными и предсказанными значениями. Средняя абсолютная процентная ошибка (MAPE) показывала отклонение прогноза в процентном выражении, что удобно для сравнения моделей на разных активах.

$$MSE = \frac{1}{n} * \sum (y_i - \hat{y}_i)^2 \quad (1),$$

$$MAPE = \frac{100\%}{n} * \frac{\sum (y_i - \hat{y}_i)}{y_i} \quad (2),$$

где y_i фактическое значение, $\hat{y}_i$ прогнозное значение

Эксперименты на данных индекса S&P 500 показали, что нейросетевые модели существенно превосходят традиционные подходы. LSTM-сеть достигла MSE 0.0021, трансформеры показали результат 0.0018, а гибридная модель – 0.0019. Для сравнения, классическая ARIMA-модель дала MSE 0.0035. Наилучшие результаты продемонстрировали трансформеры, хотя они требуют больше вычислительных ресурсов. Гибридная CNN-LSTM архитектура оказалась хорошим компромиссом между точностью и эффективностью. Визуализация сравнения моделей по MSE показана на рисунке 1.




Рисунок 1 – Сравнение моделей по MSE

*61-я Научная Конференция Аспирантов, Магистрантов и Студентов БГУИР,
Минск 2025*

Все нейросетевые подходы показали примерно на 30-50% большую точность по сравнению с традиционными методами анализа временных рядов.

Список использованных источников:

1. Hochreiter, S. Long short-term memory / S. Hochreiter, J. Schmidhuber // *Neural Computation*, 1997. – P. 1735-1780.
2. Zhang, Y. Hybrid CNN-LSTM models for financial forecasting / Y. Zhang // *Journal of Computational Finance*, 2021. – P. 45.