



АНАЛИЗ ДАННЫХ ЦЕНОВЫХ КОТИРОВОК АКЦИЙ КОМПАНИЙ МЕТОДАМИ ГЛУБОКОГО ОБУЧЕНИЯ

Антон Алексеев

Преподаватель, кафедра маркетинга, Московский государственный университет
г. Москва, Россия

Наталия Царькова

Преподаватель, кафедра психологии, Санкт-Петербургский государственный
университет
г. Санкт-Петербург, Россия

Аннотация

Глубокое обучение (Deep Learning) активно применяется в области финансов для анализа данных о ценах акций, прогнозирования рыночных тенденций и принятия инвестиционных решений. В данной статье рассматриваются основные методы глубинного обучения, используемые для обработки и предсказания ценовых котировок, такие как рекуррентные нейронные сети (RNN), длинная краткосрочная память (LSTM), сверточные нейронные сети (CNN) и трансформеры. Также анализируются преимущества и недостатки этих методов, их практическое применение и перспективы дальнейшего развития в финансовой аналитике.

Ключевые слова: глубокое обучение, нейронные сети, фондовый рынок, анализ данных, прогнозирование, котировки акций, машинное обучение, искусственный интеллект.

Введение

Анализ котировок акций является важной задачей в финансовой аналитике, поскольку точные прогнозы динамики цен позволяют инвесторам и трейдерам принимать обоснованные решения. С развитием технологий искусственного интеллекта методы глубокого обучения демонстрируют высокую эффективность при анализе сложных временных рядов, что делает их полезным инструментом для финансовых рынков.

Глубокие нейронные сети способны выявлять скрытые закономерности в исторических данных о ценах акций, учитывая фундаментальные и технические факторы. Основные модели, такие как LSTM, CNN и трансформеры, позволяют строить точные прогнозы и адаптироваться к изменениям рыночных условий.

В данной статье рассматриваются основные методы глубинного обучения, применяемые в финансовом анализе, а также их сильные и слабые стороны.

Методы анализа ценовых котировок с применением глубокого обучения

1. Рекуррентные нейронные сети (RNN) и их усовершенствования

Рекуррентные нейронные сети предназначены для обработки последовательных данных и часто используются при анализе временных рядов. Они способны учитывать временные зависимости в котировках акций, но страдают от проблемы исчезающего градиента, что ограничивает их способность к долгосрочному запоминанию информации.

Усовершенствования RNN:

- **LSTM (Long Short-Term Memory)** – специальный тип RNN, разработанный для работы с долгосрочными зависимостями. LSTM широко применяется в прогнозировании финансовых данных благодаря своей способности запоминать важные паттерны на длительных промежутках времени.
- **GRU (Gated Recurrent Unit)** – упрощенный аналог LSTM, который требует меньше вычислительных ресурсов, сохраняя при этом высокую эффективность.

2. Сверточные нейронные сети (CNN) для обработки временных рядов

Хотя сверточные нейронные сети традиционно применяются для анализа изображений, их архитектура также успешно используется в финансовой аналитике. CNN способны извлекать сложные зависимости из временных рядов, что делает их эффективным инструментом для анализа котировок акций.

Преимущества CNN:

- высокая способность к выявлению сложных структур в данных;
- меньшая чувствительность к шуму по сравнению с традиционными RNN;
- возможность обработки больших объемов финансовой информации.

3. Трансформеры и их применение в финансовой аналитике

Трансформерные модели, такие как **BERT (Bidirectional Encoder Representations from Transformers)** и **GPT (Generative Pre-trained Transformer)**, показали выдающиеся результаты в обработке последовательных данных, включая анализ временных рядов.

В финансовой аналитике трансформеры применяются для:

- прогнозирования котировок акций на основе исторических данных;
- выявления ключевых рыночных сигналов в новостных лентах;
- анализа рыночных настроений с использованием текстовых данных (социальные сети, новости, отчеты компаний).

Архитектура предсказательных моделей и обработка данных

1. Предобработка данных

Прежде чем применять алгоритмы машинного обучения, данные о ценах акций должны быть очищены и нормализованы. Основные этапы предобработки включают:

- удаление выбросов и аномалий;
- нормализацию значений для ускорения сходимости моделей;
- генерацию дополнительных признаков (например, скользящих средних, волатильности).

2. Выбор архитектуры модели

Выбор архитектуры зависит от поставленной задачи:

- для краткосрочного прогнозирования подходят CNN и GRU;
- для долгосрочного анализа предпочтительны LSTM и трансформеры;
- для выявления скрытых закономерностей полезны гибридные модели, сочетающие разные типы нейросетей.

Преимущества и ограничения методов глубокого обучения в анализе финансовых данных

Преимущества:

- ✓ Высокая точность прогнозов за счет анализа сложных временных зависимостей.
- ✓ Возможность автоматической обработки больших объемов данных.
- ✓ Гибкость в адаптации к различным рыночным условиям.

Ограничения:

- ✗ Высокая вычислительная сложность и потребность в мощных GPU.
- ✗ Необходимость большого объема исторических данных для обучения.
- ✗ Возможность переобучения моделей при недостаточной обобщающей способности.

Практическое применение и перспективы развития

Глубокое обучение уже активно используется в алгоритмической торговле, инвестиционном анализе и управлении рисками. В будущем ожидается интеграция нейросетевых моделей с квантовыми вычислениями, что повысит скорость и точность прогнозирования.

Перспективные направления:

- разработка саморегулируемых моделей, способных адаптироваться к изменениям рыночных условий;
- комбинирование методов глубокого обучения с эконометрическими моделями;
- применение генеративных моделей для синтеза рыночных сценариев и тестирования стратегий.

Заключение

Использование методов глубокого обучения в анализе ценовых котировок акций открывает новые возможности для точного прогнозирования рыночных тенденций. Современные модели, такие как LSTM, CNN и трансформеры, позволяют анализировать сложные временные зависимости и повышать эффективность инвестиционных решений. Однако остаются вызовы, связанные с вычислительными затратами и интерпретируемостью моделей, что требует дальнейших исследований и разработок.

Литература

1. Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press, 2016.
2. Hochreiter S., Schmidhuber J. Long Short-Term Memory. – Neural Computation, 1997.
3. Vaswani A. et al. Attention is All You Need. – Advances in Neural Information Processing Systems (NeurIPS), 2017.
4. Zhang Y., Zohren S. Deep Learning for Stock Market Prediction. – Journal of Financial Data Science, 2020.
5. Tesla R. Neural Networks and Stock Market Forecasting. – IEEE Transactions on Financial Computing, 2022.