

Кокшин Антон Эдуардович

магистрант

ФГБОУ ВО «Чувашский государственный

университет им. И.Н. Ульянова»

г. Чебоксары, Чувашская Республика

ЭФФЕКТИВНОСТЬ НЕЙРОННЫХ СЕТЕЙ В ПРОГНОЗИРОВАНИИ ФОНДОВОГО РЫНКА

Аннотация: в современных условиях особо актуальным является использование информационных технологий и искусственного интеллекта в прогнозировании цен различных финансовых инструментов. Все больше набирает популярность применение методов машинного обучения, один из которых – искусственные нейронные сети. В статье исследуются нейронные сети, наиболее эффективные в прогнозировании фондового рынка, определены критерии оценки эффективности искусственных нейронных сетей, оценены предлагаемые модели и выделены их ключевые особенности.

Ключевые слова: фондовый рынок, финансовые инструменты, искусственный интеллект, искусственные нейронные сети, машинное обучение.

Изменение котировок акций, облигаций и других финансовых инструментов являются последовательностью временных рядов. Задача, которая ставится перед нейронной сетью, заключается в прогнозировании этой динамики. Основным критерием эффективности прогнозов выступает их точность и стабильность. Помимо этого, нейронные сети оцениваются по следующим критериям: сложность модели, количество данных, на которых искусственная нейронная сеть (ИНС) обучалась, скорость обучения и работы.

Наиболее показательными метриками для измерения эффективности прогнозов являются:

– точность прогнозов (ТП), показывающая как часто модель правильно классифицирует данные;

– средняя абсолютная ошибка (САО) – оценка того, насколько близки предсказания к фактическим значениям;

– средняя квадратичная ошибка (СКО) – средний квадрат ошибок, характеризующий различие между прогнозируемыми и фактическими значениями;

– коэффициент детерминации (КД) – мера вариации данных, которую можно объяснить с помощью модели.

Сложность нейронной сети характеризуется ее архитектурой, которая включает в себя количество слоев, их тип, количество нейронов в каждом слое, используемой функцией активации и так далее. Точность прогнозов, скорость работы и обучения также связаны со сложностью нейронной сети. Чем сложнее модель, тем больше времени и вычислительных ресурсов требуется для обработки данных, и тем точнее будут прогнозы. Также это может привести к задержкам в работе и увеличению времени обучения.

Из вышесказанного следует, что для полноценной оценки эффективности прогнозирования фондового рынка нейронной сетью необходимо учитывать показатели, положенные в основу прогнозов, детально описать архитектуру и данные, на которых ИНС обучалась.

В исследовании «A multilayer feedforward perceptron model in neural networks for predicting stock market short-term trends» [1] авторы совместили технический и фундаментальный анализ фондового рынка с помощью гибридной ИНС. Она состоит из двух многослойных персептронов (MLP), включающих три скрытых слоя каждый, и NARX (авторегрессия с внешним входом), используемая для интеграции двух основных методов анализа фондового рынка в эту гибридную модель. Также они применяют самоорганизующиеся карты Кохонена (SOM) для кластеризации исторических цен акций.

В MLP для фундаментального анализа в 1-м, 2-м и 3-м скрытых слоях оптимизированной сети имеется 60, 51 и 1 нейрон соответственно. Между всеми слоями используется лог-сигмоидная функция активации.

В MLP для технического анализа 30, 32 и 1 нейрон в 1-м, 2-м и 3-м скрытых слоях соответственно. Функции активации между входным слоем и 1-м скрытым

слоем, 1-м и 2-м скрытыми слоями, а также 2-м и 3-м скрытыми слоями являются лог-сигмоидными. Однако последний скрытый слой, содержащий только один нейрон, связан с выходным через тан-сигмоидную функцию активации.

В качестве данных для обучения MLP, предназначенного для технического анализа, были использованы цены акций с января 1992 года по февраль 2013 года 578 компаний, торгующихся на NASDAQ, американской бирже, специализирующейся на акциях высокотехнологичных компаний. В качестве данных для обучения MLP, предназначенного для фундаментального анализа, были использованы 12 наиболее значимых финансовых коэффициентов компаний из их отчетности. В качестве же тестовых данных авторы использовали цены тех же акций и те же финансовые коэффициенты с марта 2013 года по июнь 2018 года. Для прогнозирования цены акций на один шаг вперед, модель использует в качестве входных переменных 12 финансовых коэффициентов из отчетности за предыдущий год, а также предыдущие 20 цен акции.

Данная ИНС в тестовом наборе данных показала следующие результаты: ТП = 0,7036; значения СКО распределены в достаточно хорошем диапазоне около нуля; КД = 0,99708.

В исследовании «Genetic algorithm-optimized multi-channel convolutional neural network for stock market prediction» [2] авторы предлагают метод систематической оптимизации параметров сверточной нейронной сети (CNN) с использованием генетического алгоритма (GA), который они применяют для поиска оптимальной архитектуры CNN.

В данном исследовании используется многоканальная модель CNN, включающая:

- два слоя фильтра, которые применяют свертки к входным данным и извлекают из них признаки, такие как паттерны или особенности, которые могут быть полезны для дальнейшего анализа;

- один слой пула, который уменьшает размерность данных, сохраняя при этом важные признаки, что помогает снизить вычислительную сложность и предотвратить переобучение;

– два полностью связанных слоя, которые соединяют все нейроны предыдущего слоя с нейронами следующего слоя.

Входные данные представляют собой несколько одномерных подпоследовательностей, то есть данные представляют собой последовательность значений, которые могут быть обработаны моделью, каждая подпоследовательность рассматривается отдельно, что позволяет извлекать информацию из различных временных аспектов. Далее эти подпоследовательности изучаются на отдельных временных рядах. Выходной переменной является направление движения фондового индекса на следующий день. Для повышения эффективности процедуры обучения модели данные линейно масштабируются до значения от 0 до 1. В статье описывается использование одномерных ядер для извлечения временной информации. Размер и количества ядер подбирается с помощью генетического алгоритма. В полносвязных слоях используются 200 и 40 скрытых узлов соответственно, а функция активации всех слоев лог-сигмоидная, кроме выходного, где используется линейный блок с ректификацией. Для обучения весовых параметров используется оптимизатор адаптивной оценки момента (ADAM), который эффективен для моделей глубокого обучения с нестационарными и зашумленными данными.

В исследовании для обучения используются данные ежедневного индекса KOSPI (корейский фондовый индекс, включающий в себя все компании, чьи акции торгуются на корейской бирже) с 4 января 2000 года по 31 декабря 2016 года. Исходные данные включают низкую цену, высокую цену, цену открытия, цену закрытия и объем торгов в общей сложности за 4203 торговых дня.

Входные данные:

- 1) Momentum – оценивает скорость изменения цены актива;
- 2) Stochastic K % – показывает, насколько близка текущая цена актива к его максимальной или минимальной цене за определенный период времени;
- 3) Relative strength index (RSI) – измеряет скорость и направление изменения цены актива, сравнивая среднее роста и снижения цены за определенный период времени;

4) Moving average convergence divergence (MACD) – используется для определения тренда и момента разворота рынка. Он основан на разнице между двумя экспоненциальными скользящими средними цены актива;

5) LW%R – индикатор, анализирующий максимальные и минимальные цены за определённый период и сравнивающий текущую цену закрытия с этим диапазоном;

6) A/D oscillator – используется для определения объема торговли активом;

7) Commodity channel index (CCI) – используется для определения уровня цен на рынке. Он основан на разнице между текущей ценой актива и его скользящим средним значением за определенный период времени.

Данная ИНС в тестовом наборе данных показала, что $ТП = 0,7374$. К сожалению, других метрик, что были определены как достаточно важные, авторы не приводят.

В исследовании «Stock closing price prediction based on sentiment analysis and LSTM» [3] авторы предлагают гибридную ИНС с механизмом внимания для прогнозирования цены закрытия фондового рынка на основе разложения настроений. Предлагаемая ИНС включает в себя три основных аспекта: модуль расчета индекса настроения на основе CNN, модуль разложения временных рядов на основе эмпирического разложения по модам и модуль прогнозирования на основе рекуррентной ИНС с долгой краткосрочной памятью (LSTM).

За основу модуля анализа настроений была принята модель CNN, состоящая из трех слоев: входной слой, слой свертки и слой классификации. Индекс настроений рассчитывается на основе бычьих/медвежьих биржевых комментариев, сделанных пользователями. Для классификации настроений используется модель CNN, интегрированная с word2vec, моделью для получения семантических знаний из текста.

EMD – это метод анализа сигналов, суть которого заключается в том, что он может разложить сложный сигнал на конечную собственную модовую функцию (IMF) и сумму остаточных волн. Компоненты разложенной IMF содержат локальные характерные сигналы различных временных масштабов ис-

ходного сигнала. Таким образом, алгоритм EMD разбивает исходную последовательность цен закрытия акций на несколько IMF, где первый IMF содержит высокочастотные компоненты, а последующие IMF – низкочастотные. Остаток является монотонной функцией и содержит трендовую составляющую, которая используется в модели прогнозирования LSTM.

Для более точного определения связи между различными факторами, влияющими на цену закрытия акций, применяется модель LSTM. Чтобы обеспечить сосредоточение на наиболее важной информации для достижения цели, используется механизм внимания. Переработанная модель LSTM состоит из четырех слоев: входной слой, слой LSTM, слой внимания и выходной слой.

Данные, которые были использованы для обучения и тестирования вышеописанной модели, состоят из двух частей:

1) данные для LSTM сети: цена открытия, самая высокая цена, самая низкая цена, цена закрытия и объем торгов акций Apple за все торговые дни с 4 марта 2013 года по 28 февраля 2018 года;

2) данные для CNN: комментарии, оставленные акционерами на сайте Stocktwits (социальная платформа для инвесторов, где они могут выбрать, какой тег присвоить комментарию – «медвежий» или «бычий»). Несмотря на то, что комментарии на сайте содержат мало шума, они могут не отражать мнения широкого круга инвесторов. Поэтому комментарии к акциям Apple, используемые для окончательной обработки и расчета индексов настроений, взяты с Yahoo Finance (онлайн-платформа, предоставляющая информацию о финансовых рынках, инвестициях и компаниях). Кроме того, для расчета индекса настроения выбираются комментарии, получившие большее количество «лайков». В результате для расчета индекса настроения каждый день отбирается 80 комментариев.

Эта ИНС в тестовом наборе данных показала следующие результаты: $ТП = 0,7056$; $САО = 2,396121$; $СКО = 3,196534$; $КД = 0,977388$.

В исследовании «A graph-based CNN-LSTM stock price prediction algorithm with leading indicators» [4] авторы предлагают модель, которая сочетает в себе CNN и LSTM нейронные сети. Они строят массив последовательных историче-

ских данных и их опережающих индикаторов (опционов и фьючерсов), использует его в качестве входного изображения для CNN, которая извлекает определенные векторы признаков через сверточный слой и слой объединения, а также в качестве входного вектора LSTM.

Архитектура предложенной модели разделена на три основных этапа: представление входных данных, извлечение непрерывных признаков и финальное предсказание.

На этапе представления входных данных предложенная модель использует исторические рыночные данные, чтобы прогнозировать будущие колебания рынка. Она стремится найти общую модель, которая связывает эти данные с будущими тенденциями. Кроме того, входные данные включают информацию о фьючерсах и опционах, а также десять фрагментов данных, близких по времени к основным переменным дня. Все эти данные объединяются и представляются в виде двумерного тензора.

На этапе извлечения непрерывных признаков используются идеи, заимствованные из распознавания изображений с помощью CNN. Сверточный слой объединяет ежедневные переменные в более высокоуровневые признаки, представляющие ежедневную рыночную историю. Сложные признаки генерируются в определенном временном интервале для обобщения данных.

Наконец, на этапе окончательного предсказания расширенные признаки подаются на вход LSTM, который обрабатывает их и генерирует одномерный вектор. Этот вектор используется для отображения признаков на полносвязные слои, прогнозирующие результаты торгов.

В качестве набора данных в данной работе используются десять акций с двух рынков, а именно: AAPL, IBM, MSFT, FB, AMZN – пять акций американского рынка, и CDA, CFO, DJO, DVO, IJO – пять акций рынка Тайваня. Набор включает исторические данные по акциям, фьючерсам и опционам на акции, а именно: текущую цену, самую высокую цену, цену открытия, самую низкую цену, объем, а также рост и падение. Кроме того, алгоритм выбирает 20 опционов

(10 опционов колл и 10 опционов пут), цены контрактов которых наиболее близки к текущей цене акций, чтобы сформировать массив данных по опционам.

Данная ИНС в тестовом наборе данных показала, что ТП = 0,7359. Другие метрики отсутствуют.

Среди вышеприведенных ИНС можно выделить ключевые особенности, что позволит им выдавать высокий уровень точности прогнозов, а именно:

- две из четырех ИНС являлись гибридными, сочетающими в себе несколько нейронных сетей, каждая из которых отвечала за определенные аспекты анализа;

- в исследовании ИНС с генетическим алгоритмом оптимизации, авторы сконцентрировались на настройке архитектуры с помощью GA;

- в последней рассмотренной ИНС авторы предложили гибридную модель, но в отличие от первых двух, не сочетающую анализ разных аспектов, а модель, где LSTM уточняет прогнозы CNN.

Выбор определенной модели ИНС исследователями показателен: MLP характеризуется высокой гибкостью, адаптивностью, способностью к различным оптимизациям; CNN, по своей сути, ИНС изначально разработанная для анализа изображений и видео, что крайне важна в анализе финансовых графиков; LSTM способен учитывать контекст и долгосрочные зависимости в последовательных данных.

Все авторы уделяли большое внимание оптимизации архитектуры, особенно применению генетического алгоритма.

В исследованиях обучение и тест проводились на основе данных одной отрасли, одной компании либо небольшого числа компаний, что важно, так как это позволяет заранее уменьшить количество шума.

В статье «A Comprehensive Comparative Study of Artificial Neural Network (ANN) and Support Vector Machines (SVM) on Stock Forecasting» [5] авторы проанализировали несколько десятков исследований применения искусственных нейронных сетей и метода машины опорных векторов (другой метод машинного обучения) и пришли к выводу, что нейронные сети эффективно прогнозируют

фондовый рынок. Точность прогнозов рассмотренных ими моделей варьировалась от 0,6 до 0,95. Они называют ИНС одним из лучших методов, используемых в прогнозировании, но не считают его надежным, так как при разных наборах данных каждая отдельная модель сильно отличается по эффективности.

Ключевыми особенностями ИНС, которые показали наилучшие результаты, авторы считают гибридность и грамотный подбор и подготовку данных для обучения. Многие модели сочетали несколько нейронных сетей, концентрирующихся на разных аспектах анализа фондового рынка, либо сочетали их с другими технологиями, в том числе и генетическим алгоритмом. Некоторые из самых эффективных моделей обучались на данных либо отдельной отрасли, либо отдельной компании.

Следует учесть, что вышеприведенные исследования проводились на разных фондовых рынках, поэтому нельзя с полной уверенностью утверждать о превосходстве какой-либо из них до тех пор, пока они не будут обучаться на данных одного рынка.

Исходя из всего вышесказанного, можно сделать вывод, что использование нейронных сетей в прогнозировании фондового рынка имеет большой потенциал, но несмотря на то, что ИНС могут обрабатывать большие объемы данных и выдавать точные прогнозы, они не могут гарантировать успех в инвестировании.

Точность прогнозов позволяет успешно применять ИНС, но они все еще остаются рискованными инструментами, так как работают только в краткосрочной перспективе и не учитывают неожиданных и непредсказуемых событий, которые могут привести к кардинальному изменению цен финансовых инструментов.

Для дальнейшего улучшения результатов необходимо проводить дополнительные исследования и тестирование моделей на различных данных.

Стоит разработать гибридную ИНС, которая будет сочетать в себе ключевые особенности рассмотренных выше моделей, позволившие им достигнуть высокой точности, а именно технический анализ, фундаментальный анализ,

анализ настроений, конечное уточнение прогнозов, обучение на данных одной отрасли либо одной компании.

В целом использование нейронных сетей в прогнозировании фондового рынка может быть полезным инструментом для инвесторов и трейдеров, но необходимо учитывать все возможные риски и ограничения.

References

1. Namdari A., Durrani T.S. A multilayer feedforward perceptron model in neural networks for predicting stock market short term trends // *Operations Research Forum*. – 2021. – Vol. 2. No. 38.

2. Chung H., Shin K. Genetic algorithm-optimized multi-channel convolutional neural network for stock market prediction // *Neural Computing and Applications*. – 2020. – Vol. 32. – Pp. 7897–7914. <https://doi.org/10.1007/s00521-019-04236-3>. EDN: TSZUNN

3. Jin Z., Yang Y., Liu Y. Stock closing price prediction based on sentiment analysis and LSTM // *Neural Computing and Applications*. – 2020. – Vol. 32. – Pp. 9713–9729. <https://doi.org/10.1007/s00521-019-04504-2>. EDN: OSYMNM

4. Wu J.M., Li Z., Herencsar N., Vo B., Lin J. Chun Wei A graph based CNN LSTM stock price prediction algorithm with leading indicators // *Multimedia Systems*. – 2023. – Vol. 29. – Pp. 1751–1770. <https://doi.org/10.1007/s00530-021-00758-w>. EDN: XJQVDI

5. Kurani A., Doshi P., Vakharia A., Shah M. A Comprehensive Comparative Study of Artificial Neural Network (ANN) and Support Vector Machines (SVM) on Stock Forecasting // *Annals of Data Science*. – 2023. – Vol. 10. – Pp. 183–208. <https://doi.org/10.1007/s40745-021-00344-x>. EDN: NOVWDI