

Миловидов А.Е.

Научный руководитель: кандидат технических наук, доцент А.Ю. Проскуряков
Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
e-mail: alekseimilovidov@mail.ru

Прогнозирование временных рядов финансовых активов

Помимо применения распознавания и классификации в областях медицины, обработки изображений, сигналов и текстов, множество задач прогнозирования на основе нейронных сетей, связаны со сферой бизнеса и финансов. В настоящее время искусственные нейронные сети (далее ИНС) широко применяются для решения инвестиционных -финансовых задач [1], таких как прогнозирование индекса фондовых бирж, прогнозирование банкротства и классификация корпоративных облигаций. Прогнозирование доходности фондового рынка является важным вопросом в сфере финансов. Это краткосрочные и долгосрочные прогнозы тенденций финансовых, валютных, фондовых рынков, прогнозирование платежеспособного спроса, продаж и выручки, рисков кредитования, фьючерсных контрактов и ряд других.

Любой исследуемый процесс может быть представлен в виде временного ряда. Благодаря этому становится возможным анализировать сам процесс для решения задач распознавания, классификации и предсказания с помощью различных инструментов, включая ИНС [2].

В результате эмпирических тестов различных параметров архитектуры нейронной сети, таких как количество скрытых слоев, количество нейронов во входном и скрытом слоях, была выбрана архитектура, представленная на рисунке 1. Данные параметры влияют на итоговую точность прогноза, однако простое увеличение количества скрытых слоев и нейронов в них не дает существенного прироста эффективности модели, однако значительно увеличивает вычислительную нагрузку.

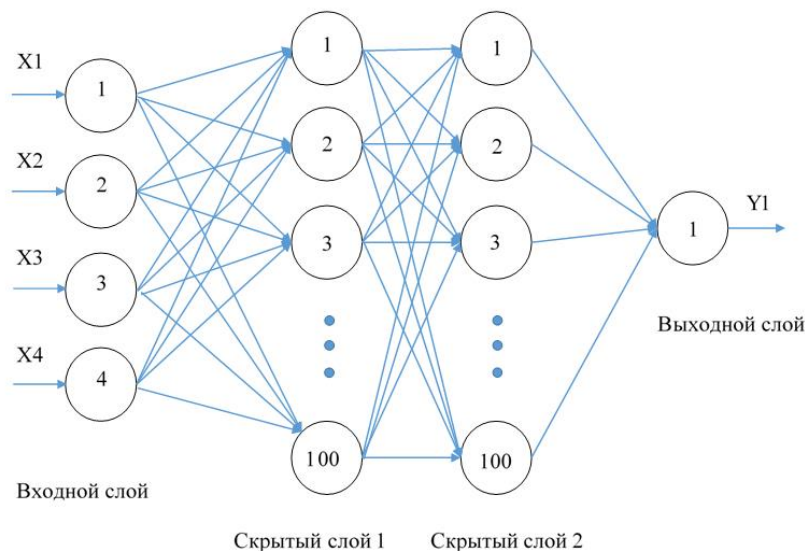


Рис. 1. Архитектура искусственной нейронной сети

Тип нейронной сети – многослойный персептрон прямого распространения. Во входном слое содержится 4 нейрона, два скрытых содержат по 100 нейронов, выходной слой имеет 1 нейрон. Метод обучения нейронной сети – алгоритм обратного распространения ошибки.

Основными гиперпараметрами изменяемыми при обучении нейронной сети являются количество скрытых слоев, количество нейронов в скрытом слое, функция вычисления ошибки (параметр loss), количество эпох при обучении (параметр epochs), метод оптимизации (параметр optimizer), а также параметр batch_size, определяющий, сколько входных векторов будет подано на вход нейронной сети до изменения весовых коэффициентов.

В результате проведенных исследований можно сделать вывод, что для решения поставленной задачи прогнозирования финансовых трендов оптимальным является использование архитектуры нейронной сети 4-100-100-1, количество эпох обучения 100, метод оптимизации – Adam, функция вычисления ошибки – Mean Squared Error.

После реализации модели искусственной нейронной сети, можно использовать ее для прогнозирования временных рядов стоимостных показателей финансовых активов [4].




Рис. 2. Результаты прогнозирования курса валютной пары USD/RUB

На рисунке 2 представлено применение разработанной нейросетевой модели прогнозирования на примере временного ряда стоимостных показателей валютной пары доллар США/рубль.

Использование нейронных сетей для анализа финансовой информации является перспективной альтернативой для традиционных методов прогнозирования в силу своей адаптивности.

Поскольку основной задачей на данном этапе исследования является определение среднесрочного тренда, а не точное предсказание ценовых уровней, в качестве недостатка разработанной искусственной нейронной сети можно выделить сложность ее применения для высокочастотного трейдинга и прогнозирования финансовых показателей со временными интервалами (таймфреймы) менее 1 дня [4].

В ходе исследования было установлено, что разработанная модель прогнозирования временных рядов финансовых показателей на базе многослойного персептрона может применяться в качестве как отдельного инструмента для анализа и прогнозирования динамики стоимости биржевых активов, в том числе активов цифровой экономики, так и в качестве дополнения к традиционным методам анализа. Показатель погрешности прогноза составляет от 9 до 32%.

Литература

1. Gudelek, Ugur & Boluk, Arda & Ozbayoglu, Murat. (2017). A deep learning based stock trading model with 2-D CNN trend detection. 1-8. 10.1109/SSCI.2017.8285188
2. Kropotov, Y. A., Proskuryakov, A. Y., & Belov, A. A. (2018). Method for forecasting changes in time series parameters in digital information management systems. Computer Optics, 42(6), 1093-1100. doi:10.18287/2412-6179-2018-42-6-1093-1100
3. Proskuryakov, A.Y. Processing and forecasting of time series in systems with dynamic parameters / 2017 International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM 2017 – Proceedings. WOSUID: WOS:000414282400259.
4. Миловидов А.Е., Кротов Ю.А., Проскуряков А.Ю. Вариативность нейросетевых инструментов в задаче прогнозирования временных рядов финансовых активов // Инновационные, информационные и коммуникационные технологии. 2019. №1. С. 103-108.