

## Прогнозирование фондового рынка с использованием нейронных сетей

*Соколова Елена Алексеевна*

*РЭУ имени Г.В. Плеханова*

*Студент*

### Аннотация

В статье исследуется метод прогнозирования фондовых рынков с помощью нейронных сетей на примере анализа и прогноза индекса ММВБ за первую половину 2017 года.

**Ключевые слова:** Нейронные сети, прогнозирование, фондовые рынки, индекс ММВБ, статистика, анализ фондовых рынков.

### Forecasting the stock market using neural networks

*Sokolova Elena Alekseevna*

*Plekhanov Russian University of Economics*

*Student*

### Abstract

The article studies the method of stock market forecasting using neural networks as an example of analysis and forecast of the MICEX index for the first half of 2017.

**Keywords:** Neural networks, forecasting, stock markets, MICEX index, statistics, stock market analysis.

### Введение

В современном мире всё с большей остротой проявляется интерес к качественному прогнозированию финансовых рынков. Это связано с быстрым развитием высоких технологий и, соответственно, с появлением новых инструментов анализа данных. Однако тот технический анализ, которым привыкли пользоваться большинство участников рынка, не эффективен. Прогнозы на основе экспоненциальных скользящих средних, осцилляторов и прочих индикаторах не дают ощутимый результат, т.к. экономика часто бывает иррациональна, потому что движима иррациональными мотивациями людей.

### 1. Что такое нейронные сети?

В последние годы, у финансовых аналитиков стали вызывать большой интерес так называемые искусственные нейронные сети – это математические модели, а также их программные или аппаратные реализации, построенные по принципу организации и функционирования биологических нейронных сетей – сетей нервных клеток живого организма [1]. Это понятие возникло при изучении процессов, протекающих в мозге при

мышлении, и при попытке смоделировать эти процессы. Впоследствии эти модели стали использовать в практических целях, как правило, в задачах прогнозирования. Нейронные сети не программируются в привычном смысле этого слова, они обучаются. Возможность обучения – одно из главных преимуществ нейронных сетей перед традиционными алгоритмами. Технически обучение заключается в нахождении коэффициентов связей между нейронами. В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными данными и выходными, а также выполнять обобщение [3]. Способности нейронной сети к прогнозированию напрямую следуют из ее способности к обобщению и выделению скрытых зависимостей между входными и выходными данными. После обучения сеть способна предсказать будущее значение некой последовательности на основе нескольких предыдущих значений и/или каких-то существующих в настоящий момент факторов [2]. Следует отметить, что прогнозирование возможно только тогда, когда предыдущие изменения действительно в какой-то степени определяют будущее. Например, прогнозирование котировок акций на основе котировок за прошлую неделю может оказаться успешным, тогда как прогнозирование результатов завтрашней лотереи на основе данных за последние 50 лет почти наверняка не даст никаких результатов [5].

## 2. Прогнозирование финансовых рынков с помощью нейронных сетей

Рассмотрим на практике применение метода прогнозирования с помощью нейронных сетей. Для примера возьмём данные индекса ММВБ в период с 09.01.2017 по 30.06.2017 [6].

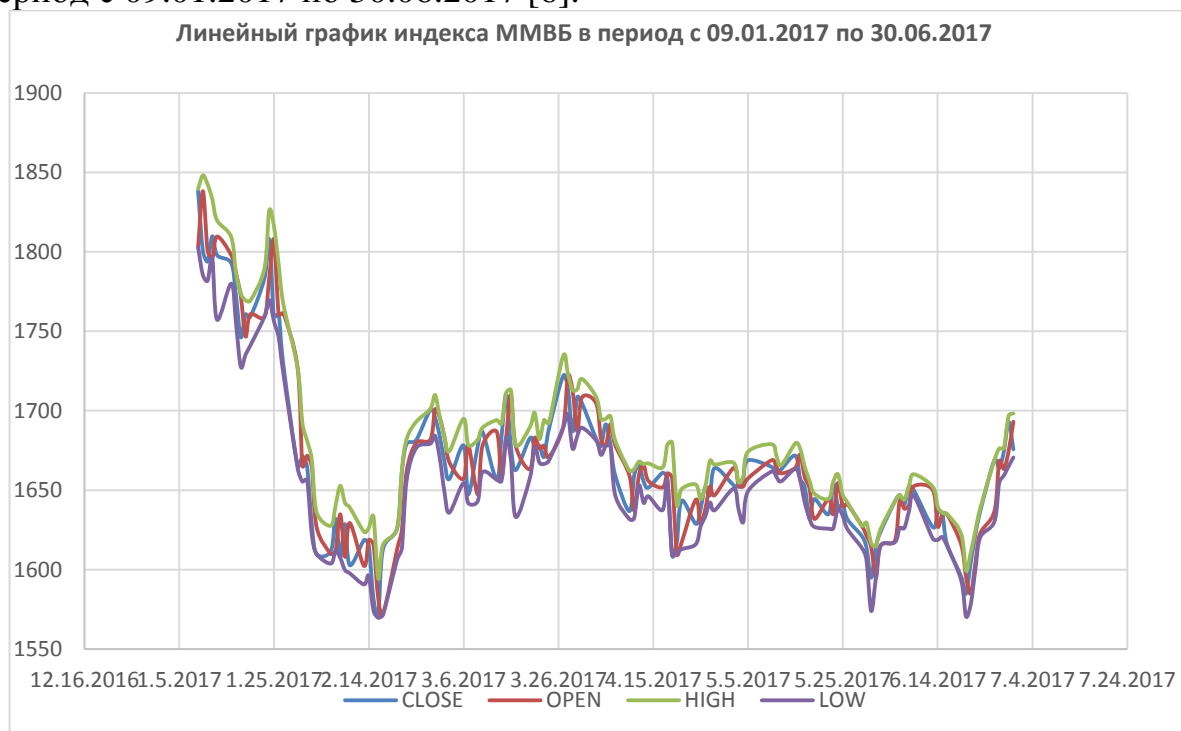


Рисунок 1 - Линейный график индекса ММВБ в период с 09.01.2017 по 30.06.2017

Задача состоит в том, что на основе представленной статистической информации необходимо сделать прогноз на 10 дней. Как видно из графика (рис.1), с 10.01.17 по 16.02.17 индекс ММВБ «просел» примерно на 279 пунктов. После чего последовал рост до максимальной отметки в 1709 пункт. Далее, некоторое время, рынок находился в боковом тренде, затем наметилась нисходящая тенденция.

В данном примере будем строить прогноз для одной переменной (остальные аналогично), но для того, чтобы выбрать ту из четырех переменных, которая наиболее сильно поможет спрогнозировать остальные, построим корреляционную матрицу (табл.1).

Таблица 1 - Корреляция показателей индекса ММВБ.

	OPEN	HIGH	LOW	CLOSE
OPEN	1,00	0,98	0,97	0,93
HIGH	0,98	1,00	0,96	0,96
LOW	0,97	0,96	1,00	0,98
CLOSE	0,93	0,96	0,98	1,00

Итак, построив матрицу парных корреляций (табл.1), делаем вывод о том, что переменная LOW наиболее сильно коррелирует с остальными. Займёмся прогнозом данной переменной.

Нелинейные по своей сути нейронные сети, позволяют с любой степенью точности аппроксимировать произвольную непрерывную функцию, не взирая на отсутствие или наличие какой-либо периодичности или цикличности. Поскольку временной ряд представляет собой непрерывную функцию (на самом деле нам известно значение этой функции лишь в конечном числе точек, но её можно легко непрерывно продолжить на весь рассматриваемый отрезок), то применение нейронных сетей вполне оправдано и корректно. [4]

Построим несколько нейронных сетей различной конфигурации в пакете STATISTICA, обучим их, а затем выберем десять наилучших.

В результате идентификации процесса построения сетей мы получили следующие результаты: выбранные сети, как можно заметить, имеют различные конфигурации (табл.2).

Таблица 2 - Тестирование сетей Мастером решений

	Архитектура	Пронзв. обуч.	Контр. пронзв.	Тест. пронзв.	Ошибка обуч.	Контр. ошибка	Тест. ошибка
1	МП s40 1:40-2-1:1	0,231126	0,270568	0,327128	0,061305	0,072517	0,082303
2	РБФ s40 1:40-10-1:1	0,323598	0,340073	0,293273	0,004162	0,004423	0,003542
3	Линейная s40 1:40-1:1	0,040462	1,751618	2,460311	0,010732	0,477302	0,660365
4	РБФ s40 1:40-16-1:1	0,311351	0,337140	0,316209	0,004005	0,004389	0,003917
5	РБФ s40 1:40-25-1:1	0,156097	0,281670	0,249106	0,002008	0,003719	0,003042
6	РБФ s40 1:40-25-1:1	0,146273	0,276806	0,185631	0,001881	0,003625	0,002385
7	РБФ s40 1:40-26-1:1	0,193419	0,253628	0,218406	0,002488	0,003302	0,002634
8	МП s40 1:40-4-1:1	0,203810	0,253800	0,403671	0,054061	0,072361	0,099805
9	МП s40 1:40-3-1:1	0,315956	0,249358	0,393732	0,083822	0,067392	0,101360
10	МП s40 1:40-2-1:1	0,443478	0,221179	0,418273	0,118314	0,059280	0,105905

В результате обучения была найдена нейронная сеть, соответствующая модели 7 (рис.2) с хорошей производительностью (регрессионное отношение: 0,253628, ошибка: 0,003302). Нетрудно заметить, что производительность сетей с архитектурой Радиально Базисной Функции (РБФ) в среднем хуже производительности сетей с архитектурой Многослойно персептрона (МП). Во многом это объясняется тем, что сети с архитектурой РБФ плохо экстраполируют данные (это связано с насыщением элементов скрытой структуры). Для оценки правдоподобности модели 7 построим гистограмму частот (рис.3). Данная гистограмма является самой симметричной по сравнению с другими моделями. Это подтверждает стандартные предположения о нормальности остатков. Следовательно, модель 7 больше всего подходит для данного временного ряда.




Рисунок 2 - Модель наиболее подходящей нейронной сети

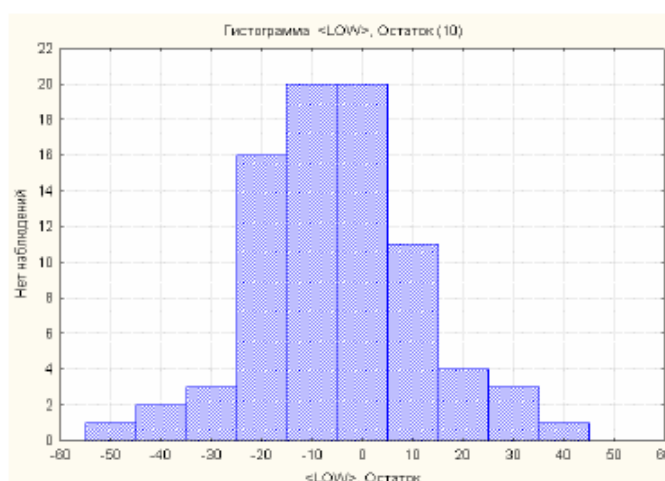


Рисунок - 3 Гистограмма частот

Осуществим проекцию для прогнозирования временного ряда. В результате имеем прогноз (рис. 4, табл. 3). Как видно из графика, нейронная сеть верно спрогнозировала направление тренда. Однако, требовать от этого метода анализа более точных данных не следует.



Рисунок 4 - График прогноза

Таблица 3 - Сравнение прогноза с реальными данными

Дата	Прогноз	Реальные данные
01.07.2017	1667,2312	1665,12
02.07.2017	1674,5367	1670,57
03.07.2017	1677,4125	1676,75
04.07.2017	1678,3635	1674,35
05.07.2017	1679,3145	1694,61
06.07.2017	1680,2655	1691,48
07.07.2017	1681,2165	1683,3
08.07.2017	1682,1675	1685,42
09.07.2017	1683,1185	1689,99
10.07.2017	1684,0695	1699,32

Как и предполагалось, нейронные сети дали хороший результат. Во многом это обусловлено сложностью и нелинейностью структуры данного ряда, тогда как классические методы рассчитаны на применение к рядам с более заметными и очевидными структурными закономерностями. Но даже, несмотря на все видимые положительные качества нейронных сетей не стоит считать их некоей «панацеей». Во-первых, нейронные сети являются «черным ящиком», который не позволяет в явном виде определить вид зависимостей между членами ряда. Таким образом, конкретную нейронную сеть можно «научить» строить прогноз лишь на строго фиксированное количество шагов вперед (которое мы указываем в спецификации этой сети), следовательно, имеет место сильная зависимость от вида задачи. Во-вторых, при наличии явной линейности, простоты структуры в задаче, способность

нейронных сетей к обобщению оказывается более слабой по отношению к классическим методам. Объясняется это как раз нелинейностью сетей по своей сути.

### **Заключение**

В данной статье описан принцип работы нейронных сетей, реализован метод прогнозирования финансового рынка с помощью нейронных сетей на примере анализа и прогноза динамики индекса ММВБ, сделаны выводы об эффективности данного метода.

На основании данной работы можно сделать вывод, что прогнозирования финансовых рынков с помощью нейронных сетей может быть достаточно эффективным, однако для достижения наилучшего результата необходимо использовать нейронные сети вкупе с грамотной стратегией управления капиталом.

### **Библиографический список**

1. Аверкин А. Н., Деньщикова Е. В. Искусственные нейронные сети и генетические алгоритмы : учебное пособие по курсу «Нетрадиционные модели вычислений» по направлению «Информатика и вычислительная техника». М. : Изд-во МЭИ, 2014 . 68 с.
2. Боровников В. STATISTICA: искусство анализа данных на компьютере. 2011. 67с.
3. Вуколов Э. А. Основы статистического анализа. М.: Форум, 2008. 189с.
4. Недосекин А. О. Нечетко-множественный анализ риска фондовых инвестиций. М.: Сезам, 2002. 154с.
5. Нейронные сети для прогнозирования. URL: <https://geektimes.ru> (дата обращения: 23.07.2017).
6. Московская биржа / Gartner. 2017. URL: <http://www.moex.com/ru/index/MICEXINDEXCF/archive> (дата обращения: 24.07.2017).