

# Constructing of an Optimal Portfolio on the Russian Stock Market Using a Nonparametric Method – Artificial Neural Network

**Elena A. Buyanova,**

candidate of physico-mathematical Sciences, associate Professor of the Department of Finance, HSE:  
26, Shabolovka str., Moscow, Russian Federation, 119049  
E-mail: bujanova@mail.ru

**Artur R. Sarkisov,**

Ph.D. of the Department of Finance, HSE: 26, Shabolovka str., Moscow, Russian Federation, 119049  
E-mail: a.sarkisov@inbox.ru

## Abstract

In this paper, a nonparametric method, the Artificial Neural Network (ANN), was used for analyzing 50 stocks, which are included in the calculation base of the MICEX stock index. This method allowed us to use not only macroeconomic and technical factors, but also factors with a limited data set (factors of fundamental analysis). As a result, we constructed an optimal portfolio with an average return of 8% higher than the market portfolio with the same risk during the period of Jan 2015 – Jan 2016.

The ANN method also allows the conduction of a comparative analysis of the influence of factors on stock return. As a result, we showed that the Russian stock market has the features of a speculative market because the most important factors for the stock return of Russian stocks are momentum, bid – ask spread, and the oil price. Significantly, the same factors were determined in the research dedicated to the problem of constructing an optimal portfolio on the Russian stock market using the classification and regression tree (CART) method. Potential investors take into account the oil price as the key determinant of the economic environment in Russia and select stocks with high momentum and high liquidity.

In this research, the ANN method was compared with another nonparametric method (CART) by solving the utility maximization problem of investors with a different coefficient value of risk aversion. As a result, the ANN method shows a strictly higher return than CART during the analyzing period. This fact could be explained by the logic of the ANN method: ANN doesn't require numerous observations of the number of independent variables. On the other hand, the CART method requires more observations because of the minimal number of observations in one node. More variables are in the structure of CART, with more nodes in the tree, and hence, more observations are required.

**Keywords:** optimal portfolio, fundamental analysis, technical analysis, portfolio selection, nonparametric methods.

**JEL:** G10, G11, G17, C14.

# Формирование инвестиционного портфеля на российском рынке акций при помощи непараметрического метода – искусственных нейронных сетей

**Буянова Елена Александровна,**

кандидат физико-математических наук, доцент, преподаватель Департамента финансов НИУ ВШЭ:  
119049, Российская Федерация, Москва, ул. Шаболовка, д. 26  
E-mail: bujanova@mail.ru

**Саркисов Артур Рачикович,**

аспирант департамента финансов НИУ ВШЭ: 119049, Российская Федерация, Москва, ул. Шаболовка, д. 26  
E-mail: a.sarkisov@inbox.ru

## Аннотация

В представленной работе проведен анализ эффективности использования метода искусственных нейронных сетей в качестве инструмента для построения оптимального портфеля акций на российском фондовом рынке. В ходе исследования для каждой акции, входящей в базу расчета индекса ММВБ, строилась нейронная сеть, входной вектор данных которой состоял из факторов макроэкономического, фундаментального и технического анализа. На основе откликов каждой сети был построен портфель, который за период январь 2015 г. – январь 2016 г. показал доходность выше, не только чем доходность рыночного портфеля с таким же риском, но и портфель, построенный при помощи непараметрического метода дерева решений.

Также использование метода нейронных сетей позволило явно выделить наиболее значимые факторы, определяющие доходность российских акций: momentum, bid-ask spread и цена на нефть. Полученные результаты свидетельствуют о наличии признаков спекулятивности российского рынка акций и полностью согласуются с выводами, полученными в работе, посвященной построению оптимального портфеля при помощи метода деревьев решений. При выборе момента для инвестирования в акции российских компаний инвесторы обращают внимание на цену на нефть, как основную макроэкономическую величину, определяющую общее состояние экономики России, и выбирают акции, показавшие себя лучше других в прошлых периодах и имеющие низкий bid-ask spread.

В работе также было проведено сравнение двух непараметрических методов (искусственных нейронных сетей и деревьев решений) путем решения задачи максимизации полезности инвестора при различных уровнях несклонности к риску. По результатам метод искусственных нейронных сетей позволяет строить оптимальные портфели с доходностью, строго превышающей доходность портфелей, построенных при помощи деревьев решений. Эффективность метода нейронных сетей по сравнению с методом деревьев регрессий можно объяснить отсутствием необходимости увеличения количества наблюдений с увеличением количества регрессоров. При этом оба метода показали высокую эффективность, позволяя получать доходность выше рыночной в оптимальном для широкого диапазона коэффициента предельной несклонности к риску.

**Ключевые слова:** оптимальный портфель, фундаментальный анализ, технический анализ, отбор бумаг в портфель, непараметрические методы.

**JEL:** G10, G11, G17, C14.

## Обзор литературы

Формирование инвестиционного портфеля является одной из наиболее важных и популярных тем современной финансовой теории. Долгое время эмпирические работы, посвященные данному вопросу, использовали в качестве инструментария стандартные модели множественной линейной регрессии. Однако подобные работы сталкивались с проблемой – очень низкой прогнозирующей способностью, а также внутренней несогласованностью параметров модели с выбранным методом. Данная несогласованность была связана с наличием жестких требований к распределению рассматриваемых величин, предъявляемых классическими параметрическими методами (например, требование к нормальности величин). Поэтому в современной экономической теории все большее количество исследователей применяют непараметрические методы анализа.

Основными преимуществами непараметрических методов являются:

- Возможность работать с короткими рядами данных.
- Отсутствие требований к распределению изучаемых величин.
- Нечувствительность к выбросам в выборке.

Одним из наиболее распространенных непараметрических методов является метод нейронных сетей. Он используется как для классификации наблюдений, так и для прогнозирования значений зависимой величины. В работе Юна и Сволеса [Yoon, Swales, 1991] был проведен сравнительный анализ классической модели множественной регрессии и метода нейронных сетей, как инструмента прогнозирования доходности акций на американском фондовом рынке. Авторы рассматривали четырехслойную нейронную сеть с 9 входными параметрами по каждой акции. Получившиеся результаты свидетельствовали о том, что прогноз, построенный при помощи искусственной нейронной сети, значительно более точен, чем прогноз, созданный при помощи регрессионного анализа.

Крижановски с соавторами [Kryzanowski et al., 1992] использовали метод искусственных нейронных сетей для отбора ценных бумаг в портфель на американском фондовом рынке на основе 14 фундаментальных показателей деятельности компаний. В результате данного анализа был получен портфель с доходностью, превышающей доходность индекса за аналогичный период. Однако автор столкнулся с проблемой низкой прогнозирующей способности нейронной сети по бумагам, которые в анализируемый период имели сильные скачки цен. Основной причиной неэффективности нейронных сетей по бумагам с резкими движениями цены указывается отсутствие в анализе каких-либо показателей технического анализа, а также маленький размер обучающей выборки.

Джанг и Лэй [Jang, Lai, 1994] в своей работе, напротив, использовали лишь показатели технического анализа, чтобы при помощи нейронных сетей прогнозировать цены акций на тайваньской бирже. В результате трехслойная нейронная сеть с 16 входными переменными не только смогла успешно прогнозировать цены акций в интервале в 21 день, но и смогла показать точность прогноза выше, чем полуметрические методы.

Фрейтас [Freitas, 2001] использовал нейронные сети для прогнозирования цен акций на бразильском фондовом рынке. Автор опытным путем отбирал количество слоев и входных параметров для нейронных сетей. В результате были получены довольно неоднозначные выводы. В самой худшей реализации нейронной сети была получена точность прогноза, составляющая 64%, а в самой лучшей реализации была получена точность 93%. Данная работа открывает одну из проблем использования не только нейронных сетей, но и других непараметрических методов анализа – чувствительность к входным настройкам модели.

Элис и Уилсон [Ellis, Wilson, 2005] отошли от простого прогнозирования цен акций при помощи нейронных сетей. Авторы попытались построить нейронную сеть для выделения из множества акций, торгуемых на австралийской фондовой бирже, акций стоимости. При помощи пяти фундаментальных и технических факторов была получена нейронная сеть, при помощи которой составили список отобранных акций стоимости, и был сформирован портфель, который показал доходность, значительно превышающую доходность индекса.

Ванстоун [Vanstone et al., 2010] использовал нейронные сети для создания оптимального торгового правила, которое базировалась на определенных соотношениях фундаментальных показателей деятельности компании. Данная работа отличается от других работ тем, что при помощи нейронной сети автору удалось составить успешный прогноз торговых позиций на временном горизонте в один год, имея в качестве обучающей выборки данные о торгах за пять лет. Кроме того, Ванстоун приводит важный момент для контроля при проведении исследований финансовых рынков – наличие «ошибки выжившего» (survivorship bias).

Проблема «ошибки выжившего» (survivorship bias) отразилась и в работе Фернадеса и Гомеса [Fernandez, Gomez, 2012], которые строили оптимальный портфель при помощи нейронных сетей, отбирая бумаги, торгуемые на DAX. Корректировка входных параметров модели при добавлении в индекс новых компаний значительно увеличила прогнозирующую силу модели.


Таким образом, видно, что искусственные нейронные сети имеют широкое применение в финансовых исследованиях и высоко эффективны. Однако также следует иметь в виду и трудности, связанные с подбором оптимальных характеристик нейронной сети, которые задаются при ее построении.

## Описание метода нейронных сетей

В работе Мерота, Моэна и Ранка [Mehrota, Mohan, Rank, 1997] дано подробное описание концепций метода искусственных нейронных сетей с возможностью небинарного отклика, которые получили широкое распространение в научной литературе.

Ниже представлена базовая схема нейронной сети.

**Рисунок 1.** Базовая схема нейронной сети



Как видно из представленной схемы, нейронная сеть имеет многослойную структуру со связями «каждый с каждым», в которых на основе загружаемых входных параметров формируется отклик.

В самом начале функционирования сети происходит формирование вектора входных данных и загрузка во входной слой. На данном этапе входные параметры должны быть масштабированы.

После прохождения входного слоя сигнал системы попадает в скрытый слой, где каждой связи между нейронами присваивается некий весовой коэффициент  $w_i$ . Изначально, при первой итерации, данные весовые коэффициенты выбираются случайно. Затем рассчитывается взвешенная сумма  $Y_i$  входного вектора и присвоенных весовых коэффициентов нейронов:

$$Y_i = \sum_{i=1}^n X_i w_i, \quad (1)$$

где  $X_i$  – нормированное значение  $i$ -го входного параметра;  $w_i$  – вес  $i$ -го нейрона.

После формирования данной взвешенной суммы входных параметров для того, чтобы сеть выдала необходимый отклик, нужно преобразовать получившуюся сумму в необходимую форму отклика. Данное преобразование выполняется при помощи функции трансформации. В зависимости от типа выбранной функции трансформации будут отличаться векторы откликов нейронной сети. Так, например, при выборе пороговой функции трансформации на выходе сеть будет выдавать бинарный отклик: либо 0, либо 1.

В представленной работе в качестве выходного отклика служил один из трех возможных исходов – по аналогии с нашим исследованием, посвященным формированию инвестиционного портфеля при помощи метода деревьев классификаций [Буянова, Саркисов, 2016]. Для финансовых активов удобно распределять наблюдения по классам в зависимости от соотношения показателя доходности по наблюдению ( $R_i$ ) и установленного порогового уровня доходности  $\bar{R}$ :

$$\begin{cases} R_i > \bar{R}, y_i = \{\text{покупка актива}\} \\ R_i < -\bar{R}, y_i = \{\text{продажа актива}\} \\ -\bar{R} \leq R_i \leq \bar{R}, y_i = \{\text{сохранение актива}\} \end{cases}.$$

Ввиду наличия трех возможных исходов была использована линейно нарастающая функция (ramp transformation function):

$$\varphi(Y) = \begin{cases} 1 & Y \geq \theta \\ 0 - \theta & < Y < \theta, \\ -1 & Y < -\theta \end{cases}, \quad (2)$$

где  $\theta$  – пороговый уровень.

В рамках данного исследования для каждой компании-эмитента была построена нейронная сеть с «прямыми связями» (feed forward), т.е. нейронная сеть без обратных взаимосвязей (движение откликов внутри сети идет лишь слева направо).

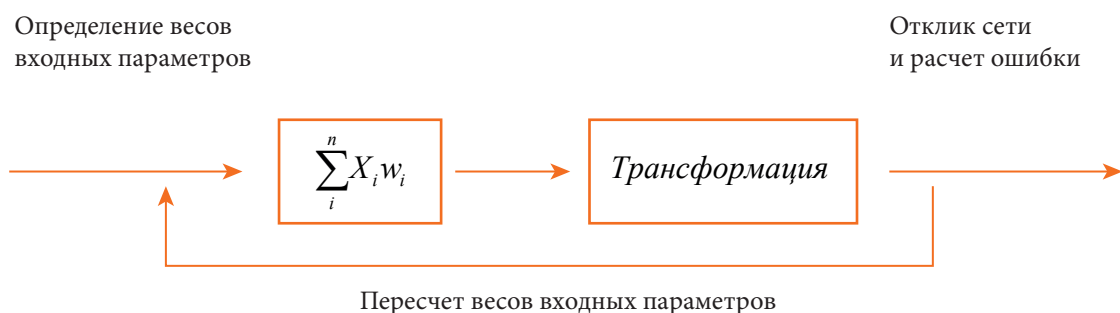
Таким образом, разобран механизм прохождения сигнала от входного слоя до выходного. Однако важнейшим механизмом функционирования нейронной сети является процесс возможности обучения.

В данной работе используется метод «обучения с учителем» (supervised learning) с обратным распространением ошибки:

1. В нулевой момент веса связей между нейронами выбираются случайным образом.
2. На основе полученных весов рассчитывается выходной вектор для обучающей выборки.
3. Вычисленный выходной вектор сравнивается с истинными значениями обучающей выборки.
4. Рассчитывается функция потерь. В данной работе функция потерь рассчитывалась как сумма квадратов отклонений.
5. Данная функция минимизируется путем подбора оптимальных входных весов
6. Пункты 2–5 повторяются, пока не будет достигнуто максимально допустимое количество итераций, когда прекратится снижение уровня ошибки.

Таким образом, обобщенную схему обучения нейронной сети можно описать следующим образом:

**Рисунок 2.** Схема процесса обучения нейронной сети



В дополнение к описанным выше механизмам работы нейронной сети следует добавить проблему подбора общих параметров сети: количества нейронов в каждом слое и так называемого коэффициента обучения.

Выбор количества нейронов в каждом слое определяет точность и скорость работы сети. С одной стороны, если будет выбрано слишком малое количество нейронов, то точность классификации и прогноза системы будут низкими, а если количество нейронов будет слишком большое, то сеть столкнется с проблемой переобучения. Переобучение (или чрезмерно близкая подгонка) – это излишне точное соответствие нейронной сети конкретному набору обучающих примеров, при котором сеть теряет способность к обобщению. Причиной переобучения может быть недостаточный размер обучающей выборки, а также чересчур сложная архитектура сети.

Вопрос оптимального числа нейронов можно решить лишь эмпирическим подбором, по результатам которого в данной работе были выбраны сети с двумя скрытыми слоями по 9 нейронов в каждом.

Коэффициент обучения, несмотря на то что он определяется также эмпирически путем подбора, несет очень важную смысловую нагрузку. В рамках представленного исследования веса входных параметров пересматривались по методу градиентного спуска. В общем виде метод градиентного спуска позволяет находить локальные минимумы функции ошибки с помощью движения вдоль градиента. Коэффициент обучения отвечает за шаг, который совершается вдоль градиента, т.е. является точностью расчета. Если шаг слишком большой, то минимум может быть недостижим, потому что функция будет постоянно «перешагивать» его. Если же точность расчета задать слишком высокой, то минимум будет достигнут, но сеть будет работать крайне медленно.

## Построение оптимального портфеля

В рамках исследования, так же как и в работе, посвященной построению портфеля при помощи метода деревьев классификации, в качестве критерия оптимальности выбрано превышение доходности составленного портфеля над рыночным портфелем с таким же параметром риска. Подобный подход обусловлен тем, что в общем виде сравнивать рыночный портфель и портфель, составленный после отсека ряда эмитентов из анализа, некорректно, т.к. рыночный портфель будет обладать более высоким уровнем диверсификации и, как следствие, меньшей доходностью.

Отбор ценных бумаг в портфель осуществлялся из множества, составленного из обыкновенных акций компаний, входящих в базу расчета индекса ММВБ. Данный выбор обусловлен тем, что данные бумаги являются наиболее ликвидными на российском рынке акций.

Для корректной классификации каждого наблюдения, входящего в выборку, на основе которой строились нейронные сети, был выбран показатель недельной доходности акций, который для периода  $t$  рассчитывался следующим образом:

$$R_t = \frac{Expected\ price_t(P_{t+1}) - P_t}{P_t}, \quad (3)$$

где:  $R_t$  – доходность акции в период  $t$ ;

$P_t$  – цена акции в период  $t$ ;

$P_{t+1}$  – цена акции в период  $t + 1$ ;

$E_t(P_{t+1})$  – ожидаемая в периоде  $t$  цена акции в периоде  $t+1$ .

Из формулы (3) видно, что для расчета доходности акции используется именно ожидаемая будущая цена акции, а не текущая стоимость. При помощи подобного способа расчета очень эффективно строить нейронные сети, т.к. в рамках процесса отбора бумаг приходится именно прогнозировать цену актива для расчета будущей доходности.

Ниже представлена таблица со списком переменных, которые использовались в построении нейронных сетей для каждой акции:

**Таблица 1.** Перечень переменных, использованных при анализе

Переменная*	Тип	Описание
Цена нефти	Макроэкономическая	Котировка нефти марки Brent
Инфляция	Макроэкономическая	Месячная инфляция рассчитывается на основе индексов потребительских цен
ROE	Фундаментальная	Return on Equity
EPS/P	Фундаментальная	Earnings per Share к цене акции
ROA	Фундаментальная	Return on Assets
ΔEPS/P	Фундаментальная	Трехмесячное изменение Earnings per Share к цене акции
Sales/P	Фундаментальная	Выручка к цене акции
Financial Leverage	Фундаментальная	$FL = \frac{Total\ Assets}{Equity}$
Interest Coverage Ratio	Фундаментальная	$ICR = \frac{EBIT}{Interest\ Coverage}$
Debt to Equity Ratio	Фундаментальная	$DtE = \frac{Total\ Liabilities}{Shareholders' Equity}$
Momentum**	Техническая	$M_t = P_t - P_{t-T}, T = 20, 30, 60, 90, 180$
MA/P	Техническая	$MA(T) = \frac{\sum_{t-T}^t P_t}{T}, T = 12, 24, 36$
Bollinger bands	Техническая	К раз стандартное отклонение МА
MA St. Error	Техническая	Стандартное отклонение МА
Bid-Ask spread,%	Техническая	$\frac{Ask\ Price - Bid\ Price}{Ask\ Price}$
Количество сделок	Техническая	Среднее дневное количество сделок за неделю

\* Данные взяты за период с января 2008 г. по декабрь 2014 г.

\*\* Под momentum подразумевается относительное место доходности определенной акции в период  $t$ .

Отдельно хотелось бы остановиться на перечне входных параметров, который используется для построения нейронной сети. Таблица 1 составлена из 16 переменных, которые загружались во входной слой сети. При этом нет никаких ограничений на количество входящих параметров, кроме технических возможностей системы, на основе которой происходит обсчет. Таким образом, метод нейронных сетей позволяет использовать одновременно наиболее полный список входных параметров, в отличие от того же метода деревьев регрессий, который требователен к количеству наблюдений.

Первичное формирование портфеля осуществлялось по следующему алгоритму:

1. Для каждой компании, входящей в базу расчета ММВБ, формировался вектор входных параметров, представленных в таблице 1. Осуществлялась корректировка на пропущенные данные, т.к. частота фундаментальных переменных (квартальная) отличалась от частоты технических переменных (еженедельной).
2. На основе данных недельных доходностей вектор начальных параметров дополнялся вектором классифицированных доходностей. Классификация происходила согласно следующему правилу:

$$\left[ \begin{array}{l} R_i > \bar{R}, y_i = \{\text{покупка актива}\} \\ R_i < -\bar{R}, y_i = \{\text{продажа актива}\} \\ -\bar{R} \leq R_i \leq \bar{R}, y_i = \{\text{сохранение актива}\}. \end{array} \right.$$

Пороговое значение доходности  $\bar{R}$  выбиралось для каждой акции индивидуально, согласно расчету средней доходности за период, взятый для формирования вектора переменных.

3. Строились нейронные сети для каждой компании и происходил подбор оптимального количества скрытых слоев и нейронов в них. В данной работе для каждой компании строились сети с двумя скрытыми слоями по 9 нейронов в каждом. Отдельно стоит сказать, что 66% всех наблюдений было отнесено к обучающей выборке.
4. На основе построенных сетей отбирались бумаги, в которых выходной сигнал состоял из {покупка актива}
5. Из пула отобранных бумаг составлялся портфель путем расчета оптимальных весов, которые являются решением следующей задачи:

$$\left\{ \begin{array}{l} \max \sum_{i=1}^n w_i r_i \\ \sqrt{\sum_{i=1}^n w_i^2 \sigma_i^2 + 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_i w_j k_{ij} \sigma_i \sigma_j} < \bar{\sigma} \\ \sum_{i=1}^n w_i = 1 \\ w_i \geq 0, \end{array} \right. \quad (4)$$

где:  $r_i$  — доходность  $i$ -й акции;  $\sigma_i$  — стандартное отклонение доходности  $i$ -й акции;

$w_i$  — доля  $i$ -й акции в портфеле.

Параметр порогового значения риска  $\bar{\sigma}$  в задаче (4) задается экзогенно и равен стандартному отклонению индекса ММВБ за анализируемый период.

После первичного формирования портфеля акций ребалансировка происходила каждый квартал. В рамках ребалансировки осуществлялись следующие действия:

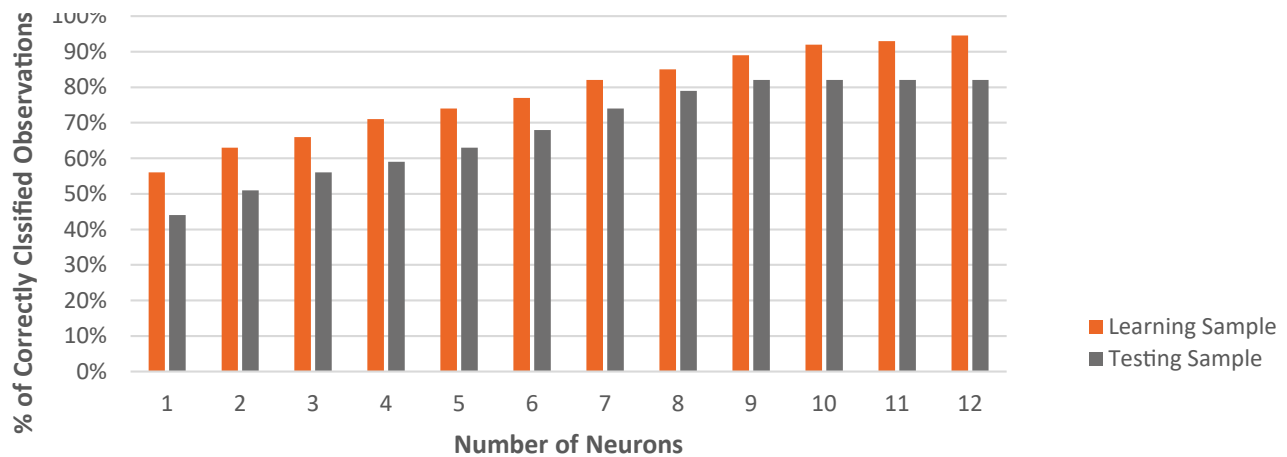
1. Вектор входных параметров для каждой компании дополнялся новыми значениями.
2. Заново строились нейронные сети для каждой компании.
3. Продавались бумаги компаний, которым был присвоен класс {покупка актива}.
4. Высвободившиеся после продажи активов средства инвестировались в бумаги с присвоенным классом {покупка актива} в пропорциях, определяемых решением задачи (4).

Как было описано ранее, оптимальным в данной работе называется портфель, доходность которого не ниже, чем доходность рыночного портфеля аналогичного риска.

Однако, прежде чем перейти к описанию результатов построения портфеля при помощи нейронных сетей, необходимо оценить эффективность построенных нейронных сетей. Для этого необходимо произвести оценку ошибок на тестовом множестве, чтобы подтвердить, что построенные нейронные сети не просто запомнили

обучающие выборки, а именно способны строить прогнозы. На графике, представленном ниже, отражены результаты тестирования сетей на тестовом и обучающем множествах при различном количестве нейронов в скрытом слое:


**Рисунок 3.** Тестирование качества нейронных сетей



Из результатов, представленных выше, видно, что на тестовом множестве качество прогноза составляло в среднем 82% при наличии 9 нейронов в каждом из скрытых слоев. При этом увеличение числа нейронов свыше 9 приводило лишь к увеличению точности на обучающей выборке, что свидетельствует о том, что сеть просто более точно запоминала исходную выборку. При этом полученные 82% точности прогноза на тестовой выборке являются приемлемым результатом для дальнейшего анализа модели.

Ниже представлены результаты тестирования модели за период с января 2015 г. по январь 2016 г., а также сравнение доходности портфеля, построенного при помощи метода нейронных сетей, с портфелем, построенным при помощи метода деревьев регрессий.


**Рисунок 4.** Разницы доходности оптимального и рыночного портфелей с одинаковым риском



Из рисунка 3 следует, что на временном горизонте с января 2015 г. по январь 2016 г. при помощи метода нейронных систем удалось построить не только оптимальный портфель, который позволяет получать доходность выше рыночной, но и такой портфель, который строго доминирует над портфелем, построенным при помощи другого непараметрического метода – деревьев регрессий.

Также был проведен анализ нормализованной важности каждого входного параметра при построении нейронной сети. Ниже представлена диаграмма нормализованной важности для компании ОАО «Магнит»:



**Рисунок 5.** Нормализованная важность входных параметров нейронной сети ОАО «Магнит»

В отличие от метода деревьев регрессий, нейронные сети позволяют в явном виде оценивать силу того или иного фактора. Ниже представлена таблица наиболее сильных факторов в зависимости от их места в нормализованной важности каждой компании.

**Таблица 2.** Ранжирование факторов в зависимости от их значимости

Переменная	Тип	Место фактора в зависимости от порядка вхождения в диаграмму нормализованной важности
Цена нефти	Макроэкономическая	1
Bid-Ask spread,%	Техническая	2
Momentum (T=30)	Техническая	3
Financial Leverage	Фундаментальная	4
Debt to Equity Ratio	Фундаментальная	5

Из результатов, представленных в таблице 2, следует, что наиболее значимыми факторами, определяющими доходность российских акций в ходе анализа при помощи нейронных сетей, оказались прямой моментум акции (с  $T = 30$ ), величина bid-ask spread и цена нефти. Примечательно, что именно эти факторы были выявлены наиболее значимыми при анализе доходностей российских акций при помощи деревьев регрессий [Буянова, Саркисов, 2016]. Этот набор наиболее значимых факторов, полученных в результате апробации модели на реальных данных, говорит в пользу гипотезы о наличии признаков спекулятивности российского рынка акций.

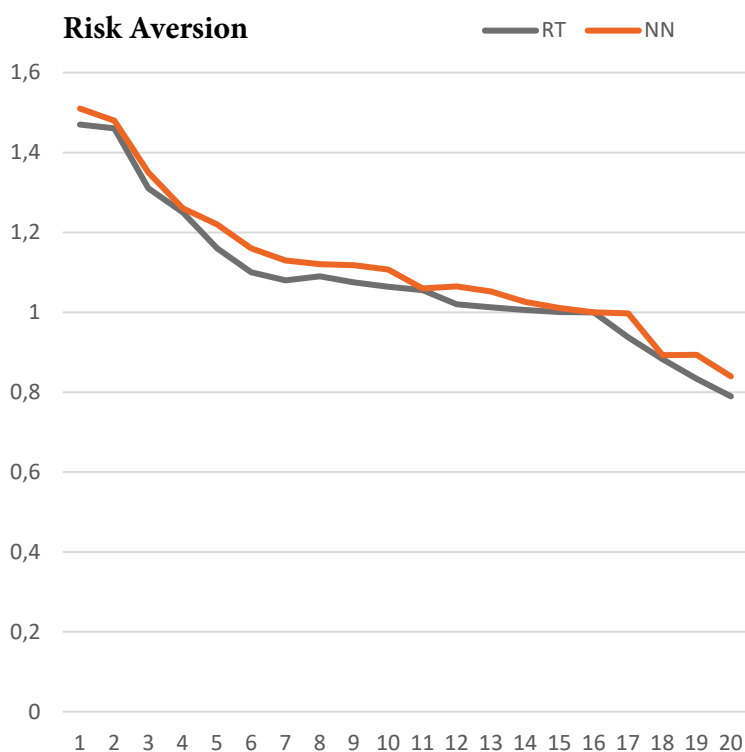
Представленный выше анализ строится на портфелях, полученных путем решения задачи (4), которая содержит в себе экзогенно заданный параметр предельного риска портфеля. Естественно, данная задача является лишь частным решением. Поэтому, для того чтобы сделать полный вывод о эффективности нейронных сетей как инструмента для построения портфеля акций, была решена следующая задача:

$$\left\{ \begin{array}{l} \max \sum_{i=1}^n w_i r_i - \delta D \\ D = \sum_{i=1}^n w_i^2 \sigma_i^2 + 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n w_i w_j k_{ij} \sigma_i \sigma_j \\ \sum_{i=1}^n w_i = 1 \\ w_i \geq 0, \end{array} \right. \quad (5)$$

где:  $\delta$  – коэффициент неприятия риска (risk-aversion);  $D$  – дисперсия портфеля.

Задача (5) решалась для значений коэффициента risk-aversion на интервале (0;20) с шагом 0,1. Ниже представлены результаты решения данных задач:

**Рисунок 6.** Нормированная доходность для различных значений *risk aversion* портфелей, построенных при помощи метода нейронных сетей (NN) и метода деревьев регрессий (RT)



Из данных, представленных выше, следует:

1. Портфель, построенный при помощи метода нейронных сетей, генерирует доходность выше рыночной для инвесторов, чей коэффициент риска неприятия лежит в промежутке (0;15).
2. Метод искусственных нейронных сетей позволяет получать доходность не ниже, чем при использовании метода деревьев регрессий.

Остановимся поподробнее на первом выводе, полученном по результатам решения задачи (5). Все представленные на рисунке 5 портфели являются оптимальными, т.к. дают максимальную полезность инвестора в зависимости от его степени неприятия риска. Абсолютно естественно, что существуют инвесторы, чья степень неприятия риска столь высока, что они предпочитают в оптимуме портфель с доходностью ниже рыночной. Однако множество подобных оптимальных портфелей (с доходностью ниже рыночной), построенных при помощи метода нейронных сетей, является решением задачи (5) с коэффициентом неприятия риска не меньше 15. При условии что стандартный коэффициент неприятия для инвестора, избегающего риска, варьируется от 10 до 12 [Япесек, 2004], при помощи метода нейронных сетей можно получить оптимальные портфели с доходностью выше рыночной для большого множества потенциальных инвесторов, которые избегают риска.

На рисунке 5 можно отметить аналогично эффективность метода деревьев регрессий в вопросе построения оптимального портфеля для инвесторов с различной степенью несклонности к риску.

## Заключение

В рамках данной работы был рассмотрен вопрос формирования портфеля акций на российском рынке при помощи непараметрического метода искусственных нейронных сетей.

В результате на основе матрицы входных параметров, включающей в себя фундаментальные, технические и макроэкономические факторы, был построен портфель акций при помощи метода нейронных сетей. Данный портфель показывал в период с января 2015 г. по январь 2016 г. доходность выше рыночной в среднем на 8 процентных пунктов. На основе данного анализа были выявлены также наиболее значимые детерминанты доходности акций российских компаний: momentum, bid-ask spread, а также цена на нефть марки Brent.

Для более полного вывода относительно эффективности данного метода был проведен анализ построения портфелей при помощи метода нейронных сетей при различных значениях параметра несклонности к риску. По результатам метод нейронных сетей является эффективным для инвесторов со значениями коэффициента несклонности к риску (0;15), что является хорошим результатом, т.к. в среднем коэффициент для не склонного к риску инвестора равен 10–12.

Помимо сравнения доходности, получаемой при помощи метода нейронных сетей с рыночной доходностью, проведено сравнение эффективности метода нейронных сетей с методом деревьев регрессий. По результатам данного сравнения, метод нейронных сетей позволяет получать в среднем доходность выше, чем метод деревьев регрессий. Одной из возможных причин этого может являться то, что метод нейронных сетей позволяет работать с большим количеством входных переменных, чем метод деревьев регрессий. Связано это с тем, что метод деревьев регрессий для построения эффективного узла, на который накладывается ограничение на минимальное количество наблюдений, с ростом количества переменных нуждается в большем количестве наблюдений.

## Список литературы

- Осовский С. (2002) Нейронные сети для обработки информации. М.: Финансы и кредит.
- Буянова Е.А., Саркисов А.Р. (2016) Формирование инвестиционного портфеля на российском рынке акций при помощи непараметрического метода – дерева решений // Корпоративные финансы. № 1, т. 37. С. 46–58.
- Ellis C., Wilson J. (2005) Can a neural network property portfolio selection process outperform the property market // *Journal of Real Estate Portfolio Management*. No. 11. P. 105–121.
- Fernandez A., Gomez S. (2007) Portfolio selection using neural networks // *Computers & Operations Research*. No. 34. P. 1177–1191.
- Freitas F. (2001) Portfolio Selection with Predicted Returns Using Neural Networks // *Neural computation*. No. 3. P. 35–54.
- Janecek K. (2004) What is a realistic aversion to risk for real-world individual investors? // *International Journal of Finance*. No. 23. P. 444–489.
- Jang G., Lai F. (1994) *Intelligent Trading of an Emerging Market*, New York: Wiley.
- Kryzanowski L., Galler M. (1992) Using Artificial Neural Networks to Pick Stocks // *Neural Networks in Finance and Investing*. No. 12. P. 525–541.
- Mehrotra K., Mohan C. (1997) *Elements of artificial neural networks*. Cambridge, Mass: MIT Press.
- Vanstone B., Finnie G. (2010) Stockmarket trading using fundamental variables and neural networks. *Neural computation*, no. 7, pp. 58–74.
- Yoon Y., Swales G. (1991) Predicting stock price performance: A neural network approach. *System Sciences*, no.4, pp. 156–162.
- Osowski S. (2002) *Nejronnye seti dlya obrabotki informacii* [Neural Networks and Machine Learning]. Moscow: Finance and Credit. (In Russ.)
- Bujanova E.A., Sarkisov A.R. (2016) Formirovanie investicionnogo portfelya na rossijskom rynke akcij pri pomoshhi neparametricheskogo metoda – dereva reshenij [Constructing of Optimal Portfolio on Russian Stock Market Using Nonparametric Method – classification and regression tree]. *Korporativnye financy*, no. 1, pp. 46–58. (In Russ.)
- Ellis, C., Wilson, J. (2005) Can a Neural Network Property Portfolio Selection Process Outperform the Property Market. *Journal of Real Estate Portfolio Management*, no. 11, pp. 105–121.
- Fernandez, A., Gomez, S. (2007) Portfolio selection using neural networks. *Computers & Operations Research*, no. 34, pp. 1177–1191.
- Freitas, F. (2001) Portfolio Selection with Predicted Returns Using Neural Networks. *Neural computation*, no. 3, pp. 35–54.
- Janecek K. (2004) What is a realistic aversion to risk for real-world individual investors? *International Journal of Finance*, no. 23. pp. 444–489.
- Jang G., Lai F. (1994) *Intelligent Trading of an Emerging Market*, New York: Wiley.
- Kryzanowski L., Galler M. (1992) Using Artificial Neural Networks to Pick Stocks. *Neural Networks in Finance and Investing*, no. 12, pp.525–541.
- Mehrotra K., Mohan C. (1997) *Elements of artificial neural networks*. Cambridge, Mass: MIT Press.
- Vanstone B., Finnie G. (2010) Stockmarket trading using fundamental variables and neural networks. *Neural computation*, no. 7, pp. 58–74.
- Yoon Y., Swales G. (1991) Predicting stock price performance: A neural network approach. *System Sciences*, no.4, pp. 156–162.