

Министерство образования и науки Российской Федерации
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ
ВЫСШЕГО ОБРАЗОВАНИЯ
«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИМЕНИ Н.Г. ЧЕРНЫШЕВСКОГО»

Кафедра Математического и компьютерного моделирования

ПРОГНОЗИРОВАНИЕ ФИНАНСОВЫХ ПОКАЗАТЕЛЕЙ

ФАРМАЦЕВТИЧЕСКИХ КОМПАНИЙ С ПОМОЩЬЮ

КОМИТЕТОВ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Автореферат магистерской работы

студента 3 курса 391 группы

направление 38.04.01-экономика

механико-математического факультета

Уваров Максим Николаевич

Научный руководитель

зав.каф., д.ф.-м.н.

Ю.А. Блинков

Зав. кафедрой

зав.каф., д.ф.-м.н.

Ю.А. Блинков

Саратов 2017

ВВЕДЕНИЕ

В настоящее время прогноз фондового и валютного рынка является областью финансового прогнозирования, что привлекает к себе внимание во всем мире ученых из финансово - экономической сферы. Само существование и развитие любых видов рынков базируются на регулярных обменных операциях и вливании инвестиций. Поэтому современная система прогнозирования является необходимым элементом финансового управления в любой компании. В данной магистерской работе рассмотрены особенности финансового развития и прогнозирования на основе компаний фармацевтического профиля.

Макроэкономическое моделирование экономического роста имеет большое значение в экономических событиях и политики, но нет никаких эффективных методов моделирование. Результативность применения традиционных методов прогнозирования финансовых активов (акций, облигаций, валют) не до конца удовлетворяет потребности. Ограниченность стандартных методов заключается в их зависимости от исходных условий и отсутствии гибкости. Для этой цели могут быть использованы несколько архитектур нейронных сетей (НС) для построения нейронных моделей, имитирующих сложную динамику всей экономической системы, в целом, и в частности отношений ВВП (рост национального продукта), финансовые доходы рабочей силы (трудовые ресурсы), показатели финансового рынка и цен на отраслевые структуры экономики. В финансовом анализе искусственные НС рассматриваются как механизм перестройки репрезентативного агента, принимающего решения [1].

Целью выпускной работы является теоретическая оценка финансового функционирования фармацевтических компаний и применение математических методов прогнозирования, в частности - нейронные сети.

Конечными пользователями полученных данных могут стать все сотрудники, занимающиеся финансово-экономической аналитикой, или как-то связанные с финансами.

Для достижения цели были сформулированы следующие задачи исследования:

- изучение теоретических основ финансового планирования и прогнозирования;
- теоретическая оценка основных методов и моделей финансового прогнозирования с использованием методов математической статистики, в частности комитетов нейронных сетей;
- рассмотрение особенностей функционирования фармацевтического рынка и деятельность функционирующих компаний;
- разработка принципов оценки финансовых перспектив с использованием нейронных сетей;

Данная работа состоит из трех разделов:

- Теоретические и методологические основы прогнозирования финансовых показателей с использованием комитетов искусственных нейронных сетей
- Процесс прогнозирования финансовых показателей фармацевтических компаний с использованием искусственных нейронных сетей
- Модели управления и использования прогноза финансовых показателей фармацевтических компаний с помощью искусственных нейронных сетей

Результаты, полученные в ходе подготовки магистерской работы, докладывались на:

- VI Международной молодёжной научно-практической конференции «Математическое и компьютерное моделирование в экономике, страховании и управлении рисками», г. Саратов, 2017;

- Международной научно-практической конференции «Инновации и инвестиции как драйверы социального и экономического развития», г. Челябинск, 2017.

Основное содержание работы

Первый раздел включает в себя описание теоретических и методологических основ прогнозирования финансовых показателей с использованием искусственных нейронных сетей. Под искусственными нейронными сетями (далее – просто нейронными сетями или нейросети) подразумевают вычислительные структуры, состоящие из большого количества однотипных элементов, каждый из которых выполняет относительно простые функции [3]. Нейросети нашли применение в достаточно обширном количестве областей человеческой деятельности, а именно: экономике и бизнесе, медицине, связи, автоматизации производства, робототехнике, интернете, безопасности и охранных системах, геологоразведки и т.д. Просто нейросети – это гибкий и мощный набор инструментов для решения разнообразных задач обработки и анализа данных [2].

Подход к прогнозированию временных рядов с использованием искусственных нейронных сетей обладает рядом неоспоримых достоинств. Во-первых, нейросетевой анализ, в отличие от технического, не предполагает никаких ограничений на характер входной информации. Это могут быть как индикаторы данного временного ряда, так и сведения о поведении других рыночных инструментов. Во-вторых, в отличие от технического анализа, основанного на общих рекомендациях, нейросети способны находить оптимальные для данного инструмента индикаторы и строить по ним оптимальную опять же для данного ряда стратегию предсказания. Более того, эти стратегии могут быть адаптивны, меняясь вместе с рынком, что особенно важно для молодых активно развивающихся рынков.

В нейронных сетях вычислительные операции выполняются отдельно большим количеством относительно простых процессорных элементов. Структура нейронной сети соответствует математической структуре вычислительной системы, где все операции производятся в отдельных узлах, а поток информации представляется направленными ребрами графа. В целом

искусственная нейронная сеть является адаптивной нелинейной динамической системой. С помощью равновесных состояний данной сети можно решать различные математические и вычислительные задачи.

Различают два вида нейронных сетей:

- сети, обучаемые с учителем;
- сети смешанного обучения.

Преимущество нейросетевого моделирования, как инструмента анализа и исследования, заключается в построении параллельных процессов обработки информации и возможности искусственных нейросетей самообучаться. Подобные характеристики приобретают особое значение при решении задач, находящихся в фокусе данной работы. Поэтому, необходимо более детально рассмотреть все «полезные» для нас свойства моделей, основанных на искусственных нейронных сетях [3]:

- 1) Нелинейность;
- 2) Адаптивность;
- 3) Отсутствие априорных наблюдений (обучение «с нуля»);
- 4) Единообразия и гибкость.

Нейронная сеть способна выявлять сложные зависимости между входными и выходными данными и выполнять их обобщение. Значит нейронная сеть может дать результат даже при условии, что на входе были использованы искаженные, неполные данные. Это одна из характерных черт искусственного интеллекта, способность работать в ограниченных условиях, как и человек.

Выделяют следующие этапы решения задач в нейросети [4]:

- сбор данных для обучения;
- подготовка и нормализация данных;
- выбор топологии сети;
- экспериментальный подбор характеристик сети;
- экспериментальный подбор параметров обучения;

- собственно обучение;
- проверка адекватности обучения;
- корректировка параметров, окончательное обучение;
- вербализация сети с целью дальнейшего использования.

Задача разделения конечных множеств с помощью одной линейной пороговой функции — это задача нахождения решения системы линейных неравенств. Если два множества в конечно-мерном евклидовом пространстве не имеют общих точек, то всегда можно с помощью полной системы формальных нейронов (например, системы линейных пороговых функций) перейти в такое спрямляющее пространство, в котором образы классов при этих отображениях окажутся аффинно-разделимыми. Однако в практических задачах трудно указать конкретно такие преобразования, так как обычно неизвестно, сколько формальных нейронов и каких надо использовать, чтобы обеспечить достаточную аппроксимацию дискриминантной функции.

Метод комитетов позволяет обойти эту трудность, но он имеет и более общее значение. Комитеты дают обобщение понятия существования объектов. Объект может не существовать в обычном смысле — как единичный целостный объект, например, в несобственных задачах дискриминантного анализа и оптимизации, но может существовать в размытом смысле как некоторый коллективный объект. далее, p -комитеты связаны с понятием процента объектов с заданными свойствами в некоторой выборке.

Приложения комитетных конструкций разнообразны. Поэтому важно иметь методы построения комитетов. Среди первоначально предложенных методов поиска решений систем линейных неравенств были итерационные методы обучения персептронов. С математической точки зрения это многочисленные итерационные методы решения систем линейных неравенств. При этом если неравенства строгие, а их система совместна, то многие из методов оказались, конечно, шаговыми. Таким является, например,

метод линейной коррекции, который можно (модифицировав) применить к поиску комитетов.

Другая группа методов — собственно методов построения комитетов — использует поиск решений максимальных совместных подсистем системы линейных неравенств. Это может быть сделано либо с помощью метода исключения неизвестных (фундаментального свертывания), либо через сведение к многоэкстремальной оптимизации.

Во втором разделе формулируются цели и происходит постановка задач прогнозирования финансовых показателей фармацевтических компаний. Рассмотрены данные развития фармацевтического рынка в России в 2017 г. Он состоит из двух основных сегментов: коммерческого и государственного. Коммерческий сегмент фармацевтического рынка включает в себя аптечные продажи ЛП и парафармацевтики без учета продаж по Программе ДЛО (Дополнительное лекарственное обеспечение).

Государственный сегмент фармацевтического рынка включает в себя аптечные продажи ЛП по Программе ДЛО, а также реализацию через ЛПУ (лечебно – профилактическое учреждение). Интерес для исследования больше представляет коммерческий рынок. Его объем лекарственных препаратов (далее ЛП) в сентябре 2017 г. составил 59,6 млрд. руб. (с НДС). По итогам этого месяца 59 % препаратов, реализованных на рынке, являются отечественными, однако в виду своей невысокой цены относительно импортных лекарств, в стоимостном выражении они занимали 29 % . Рейтинг компаний по стоимостному объему продаж в сентябре 2017 г. возглавила компания Bayer, на втором месте – Novartis, на третьем и четвертом месте – Sanofi и Glaxosmithkline [5]. На основании финансовой деятельности этих компаний и будем производить расчёты.

Для обучения и тестирования нейронной сети использовались данные котировок интересующих компаний, предоставляемые брокерской компанией АО «Инвестиционный холдинг ФИНАМ» (Сайт: <http://www.finam.ru> /). Данные сохранялись в формате .csv. Для их обработки из

экспортированного файла и формирования в начальные входные данные для нейронной сети был реализован специальный модуль по взаимодействию с Excel - файлами. В границах данной работы будут использованы значения цен закрытия. Но будут использоваться не абсолютные значения цен закрытия, а изменения котировок в качестве входов – и, соответственно, формат выходов является таким же. В качестве обучающей и тестовой выборки использовались котировки биржевых активов в период с 01.01.2014 по 01.01.2016 и с 01.01.2016 по 15.05.2016 соответственно двух ценных бумаг, эмитированных компаниями банковского сектора – Bayer и Novartis – и биржевые инструменты, представляющие фармацевтическую отрасль – Sanofi и Glaxosmithkline. Данный выбор обусловлен желанием не только провести анализ эффективности использования нейронных сетей для прогнозирования цен конкретных инструментов, но и попыткой обобщить полученные данные для отрасли, сектора экономики.

Экспортированные данные включают следующие значения:

- цена открытия – цена финансового инструмента на момент заключения первой сделки в выбранном временном интервале (тики, 5мин, час и т.д.);
- цена закрытия – цена финансового инструмента на момент заключения последней сделки;
- максимальная цена;
- минимальная цена;
- объем торгов.

Первым этапом анализа является сравнение оценок качества адаптивных предсказаний многослойного перцептрона для каждого рассматриваемого инструмента, при условии, что нейронная сеть обучалась на всем массиве данных и обучение производилось на «своих» (финансовый временной ряд данного инструмента) данных соответственно. Для получения данных на этом этапе использовался трехслойный перцептрон с количеством нейронов во входном слое от 8 до 12, первом, втором и третьем скрытом, и в выходном

– один нейрон, для определения вектора изменения цены. Параметры «скорость обучения» и «момент» фиксировались со значениями 0.75 и 0.2 соответственно. Полученные средние результаты, а так же разброс предсказаний в соответствии с «Таблицей 1».

Таблица 1 - Сравнение результатов прогнозирования нейронной сети, в зависимости от обучающей выборки

	Bayer	Novartis	Sanofi	Glaxosmithkline
Обучение на всем эмпирическом массиве данных(1)				
Средний результат	59,956 %	60,865 %	58,73 %	59,337 %
Разброс	51,49 % - 69,19 %	48 % - 71,63 %	51,95 % - 64,92 %	56,01 % - 65,37 %
Обучение на «своих» исторических данных (2)				
Средний результат	62,139 %	64,22 %	60,034 %	61,157 %
Разброс	52,62 % - 78,16 %	51,62 % - 81,46 %	56,34 % - 68,92 %	52,64 % - 72,36 %

В соответствии с заданными промежутками размеров слоев нейронной сети, было получено по 900 предсказаний для каждого инструмента при (1) и (2). Дабы графическое отображение имело смысл, полученные результаты группировались по 10 (по принципу ближайших) и на графике отмечалось среднее значение группы. В итоге полученные результаты можно увидеть на рисунках 1-4.



Рисунок 1 - Результаты компании Bayer



Рисунок 2 - Результаты компании Novartis



Рисунок 3 - Результаты компании Sanofi



Рисунок 4 - Результаты компании Glaxosmithkline

Из полученных результатов можно сделать вывод, что искусственная нейронная сеть, представляющая собой искусственный перцептрон с обратным распространением ошибки показывает более высокое качество предсказания направления динамики изменения биржевой цены актива при обучении сети на исторических данных исключительно исследуемого инструмента, в сравнении с обучением на всем эмпирическом массиве (в рамках конкретного исследования) данных. Таким образом, построенная модель эффективнее анализирует и прогнозирует изменения котировок инструмента тогда, когда «историческая информация», обучающая выборка, рассматривается вне контекста общей «информации» о рынке, отрасли, секторе. При второй выборке предсказания получаются с наименьшей стабильностью, связанной с тем, что многослойный перцептрон, обучающийся на всем объеме эмпирических данных, аппроксимирует функцию финансового временного ряда биржевого инструмента с меньшей амплитудой флуктуаций качества, в отличие от обучения на обособленных от рынка собственных данных. Может объясняться тем, что отсутствует информация в полном объеме в обучающей выборке или / и сильной зашумленностью входных данных.

Следующий момент, который необходимо отметить, - адаптивные предсказания нейронной сети для биржевых инструментов, представляющих фармацевтическую отрасль, показывают большую стационарность в совокупности с меньшим качеством. По мнению автора, данный эффект связан с макроэкономическими процессами и институциональными изменениями в экономике России, которые имели место быть в течение исследуемого периода.

Как отмечалось выше, увеличение амплитуды колебания оценки качества адаптивных предсказаний может быть связано с наличием высокого уровня «шума» во входных данных, что ставит под сомнение релевантность используемой выборки. Таким образом, вторым этапом анализа эффективности работы многослойного перцептрона будет являться внедрение в модель метода предварительной обработки массива данных, основанного на методе выделения главных компонент, для повышения статистической значимости выборки. Параметры нейронной сети остаются прежними, как и на первом этапе анализа. Полученные результаты приведены в «Таблице 2».

Таблица 2 - Полученные результаты

	Bayer	Novartis	Sanofi	Glaxosmithkline
Среднее значение (1 этап)	62,139 %	64,22 %	60,034 %	61,157 %
Среднее значение (с предв. обработкой)	66,056 %	67,187 %	65,702 %	65,34 %
Разброс (1 этап)	52,62 % - 78,16 %	51,62 % - 81,46 %	56,34 % - 68,92 %	52,64 % - 72,36 %
Разброс (с предв. обработкой)	56,77 % - 81,26 %	55,36 % - 85,63 %	58,77 % - 74,13 %	56,37 % - 73,92 %

Как видно из таблицы: среднее значение оценки качества прогнозирования выросло для всех финансовых инструментов. Наибольшее увеличение, $\approx 5,668\%$, было достигнуто для инструмента «Sanofi» - такой эффект дает право отнести данные о биржевых ценах актива к сильно зашумленным. Также важным моментом является «сдвиг» нижней границы (величина наихудшей оценки качества) в сторону увеличения для всех

исследуемых инструментов. Следуют также отметить, что не было установлено корреляции между внедрением метода главных компонент и уменьшением/увеличением амплитуды колебаний оценок (разброс остался приблизительно на том же уровне). Таким образом, внедрение в модель механизма предварительной обработки входных данных являлось верным исследовательским шагом.

На третьем этапе проведена попытка выявить корреляцию (или установить ее отсутствие) между ростом/снижением качества прогнозирования и количеством слоев в нейронной сети (остальные характеристики сети остаются прежними). Подобный шаг допустим. В соответствии с «Таблицей 3» приведены результаты для исследуемых инструментов:

Таблица 3 - Результаты для исследуемых инструментов

Показатель	Bayer	Novartis	Sanofi	Glaxosmithkline
Однослойный перцептрон				
Среднее значение	58,638 %	53,783 %	60,164 %	61,01 %
Разброс	48,21 % - 66,71 %	43,64 % - 75,28 %	53,89 % - 69,14 %	52,73 % - 78,26 %
Двухслойный перцептрон				
Среднее значение	63,327 %	61,934 %	63,207 %	61,93 %
Разброс	51,69 % - 76,31 %	50,26 % - 79,21 %	59,08 % - 70,96 %	56,37 % - 71,63 %
Трехслойный перцептрон				
Среднее значение	66,056 %	67,187 %	65,702 %	65,34 %
Разброс	56,77 % - 81,26 %	55,36 % - 85,63 %	58,77 % - 74,13 %	56,37 % - 73,92 %
Четырехслойный перцептрон				
Среднее значение	66,732 %	68,036 %	65,326 %	64,71 %
Разброс	55,23 % - 84,07 %	55,02 % - 85,47 %	54,23 % - 74,87 %	59,19 % - 72,43 %
Пятислойный перцептрон				
Среднее значение	64,962 %	68,739 %	65,187 %	67,04 %
Разброс	59,16 % - 80,92 %	54,27 % - 87 %	60,64 % - 78,16 %	53,98 % - 84,36 %

На основе полученных результатов можно сделать вывод для данного исследования:

Искусственная нейронная сеть - многослойный перцептрон - способна решать задачу прогнозирования финансовых временных рядов с различным уровнем качества, в зависимости от количества слоев (N) в архитектуре сети. Причем, для исследуемых инструментов, повышение N в промежутке приводит к увеличению качества адаптивных предсказаний (K). Корреляция между N и K, для $N > 3$, не установлена. В рамках данного исследования, $N > 2$, где N – количество слоев многослойного перцептрона, является необходимым, но не достаточным, условием оптимальности (в том значении, которое определяется в данной работе) прогнозирования финансовых временных рядов. Поэтому весь остальной анализ будет проводится с использованием трехслойного перцептрона.

Четвертый этап. На данном этапе анализируется степень влияния выбора активационной функции на качество полученных результатов. Полученные результаты представлены в «Таблице 4»:

Таблица 4 - Общий результат оценки

Показатель	Bayer	Novartis	Sanofi	Glaxosmithkline
Логистическая функция: $f(u) = \frac{1}{1 + e^{-tu}}$				
Среднее значение	65,837 %	67,121 %	66,33 %	64,431 %
Разброс	55,93 % - 83,02 %	54,49 % - 84,64 %	58,19 % - 74,92 %	55,17 % - 74,67 %
Функция гиперболического тангенса: $f(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}}$				
Среднее значение	66,382 %	67,307 %	64,921 %	65,983 %
Разброс	56,32 % - 80,67 %	52,46 % - 86,91 %	58,83 % - 74,08 %	57,39 % - 73,72 %

Формальный вывод на данном этапе: использование функции гиперболического тангенса повышает качество предсказаний нейронной сети для трех инструментов из четырех и только для инструмента «Sanofi» предпочтительнее использовать логистическую функцию активации. Однако

стоит отметить, что разница в качестве является сравнительно небольшой и, что более важно, может быть вызвана некоторыми «выбросами» статистики (так как сеть работает с конкретными инструментами, анализируя данные определенного интервала). С учетом вышесказанного, а также принимая во внимание ограниченную выборку анализируемых объектов (биржевых инструментов), по итогам четвертого этапа анализа был сделан вывод: ни одна из рассматриваемых в данном исследовании функций активаций нейрона не может быть определена как мажоранта. Следовательно, для предотвращения потери качества прогнозирования, необходимо использовать несколько функций активации с последующим выбором «лучшей» для данной конкретной задачи (инструмент, анализируемый на определенном интервале).

Пятый этап. На всех предшествующих этапах анализа эффективности работы многослойного перцептрона размер «скользящего окна» (размер массива данных, которые подаются на вход нейронной сети) не был фиксирован, а изменялся в соответствии с указанным промежутком. Но, в рамках данного исследования, необходимо установить оптимальный размер окна для каждого из анализируемых инструментов.

Анализ взаимосвязи между «длиной» входных данных и точностью прогноза для каждой из четырех акций позволил сделать следующий вывод: в рамках данного исследования было установлено, что существует корреляция между размером входных данных для нейронной сети и величиной качества прогнозирования. Причем, для всех финансово-биржевых инструментов наблюдается одинаковая тенденция роста/снижения точности прогноза на всех участках изменения размера «скользящего окна».

В результате данного исследования была построена и реализована оптимальная для каждого из инструментов (Bayer, Novartis, Sanofi, Glaxosmithkline) искусственная нейронная сеть на основе модели многослойного перцептрона, которая эффективно решает задачу

прогнозирования направления динамики изменения цен на данный биржевой актив.

В третьем разделе разработаны модели управления фармацевтической компанией на основе прогноза финансовых показателей. Есть несколько общих рекомендаций, которые подойдут современным компаниям и на которые стоило бы обратить внимание, если компания хочет вырасти и увеличить прибыль.

Первая рекомендация заключается в реорганизации исследований для фокусирования на терапевтических областях. Чем больше становятся международные корпорации, тем больше они подавляют инновации. Крупные компании пытаются охватить как можно больше областей, пытаются получить как можно больше прибыли, предлагая ограниченную линейку препаратов. Одним из решений может быть сосредоточение внимания только на нескольких областях, например, на диабете или онкологии.

Рекомендация №2 - исследовательский фокус на крупных биологических препаратах. Для многих фармацевтических компаний наиболее важным критерием при определении того, какой препарат следует разрабатывать, является возможность заработать на нем от 1 млрд. долларов в год. Ориентация на стратегию блокбастеров очень рискованна, потому что, если продукт провалится, это приведет к пробелам в ассортименте компаний. Международные компании стремятся разработать маломолекулярные лекарственные препараты, предназначенные для больших групп пациентов, однако, они не всегда приносят пользу. Маломолекулярные препараты обычно не так действенны, потому что не подходят для тонкой специфики каждой отдельной болезни, ранее такая стратегия была финансово успешной, но в ближайшем будущем может перестать работать, так как современная медицина научилась разрабатывать лекарства, более тесно связанные с генетическим составом конкретных людей.

Рекомендация №3 - научный подход к диагностической стратегии. Многие пациенты либо не получают диагностику своевременно, либо не

получают ее вообще. Повышение квалификации диагностики и обучения врачей может значительно увеличить число людей, получающих диагноз, и, следовательно, увеличить число пациентов, получающих лечение, что приведет к увеличению доходов фармацевтических компаний.

Рекомендация №4 - лицензионные возможности. По мере роста конкуренции за составы цены будут расти вместе с повышением эффективности рынка. Для получения прибыли компаниям необходимо будет привлечь специализированные активы к процессу лицензирования. Есть два способа, которые фирма может использовать для этой цели. Например, лицензировать раньше. Лицензионные сделки, как правило, характеризуются относительно высоким уровнем отказов - в среднем 37% являются успешными, более 60% продуктов, получивших лицензию на 3 этапе или клинических стадиях, достигают рынка по сравнению с только 20% товаров, которые находятся на 1 и 2 фазе испытаний. Компании склонны отдавать предпочтение лицензированию соединений на более поздних стадиях цикла разработки, после того как значительная часть риска устранена.

В ходе исследования было выделено и структурировано три основных стратегии роста в медицинских компаниях:

- 1) слияние и поглощение;
- 2) лицензирование новых составов;
- 3) создание стратегических альянсов и партнерских отношений с другими фармацевтическими или биотехнологическими компаниями.

ЗАКЛЮЧЕНИЕ

В работе рассматривался один из возможных подходов к решению задачи анализа и прогнозирования – нейросетевой. Было установлено, что искусственные нейронные сети могут эффективно справляться с указанной задачей. Связано это, главным образом, с адаптивностью такого рода моделей. Являясь по своей сути функцией нелинейного отображения, нейронные сети обладают еще одним существенным преимуществом перед более строгими традиционными методами технического анализа, с той точки зрения, что могут работать с любой структурой входной информации (с разной степенью эффективностью конечно).

В ходе теоретического исследования была доказана состоятельность нейросетевого подхода к анализу финансовых показателей компаний, функционирующих на фармакологическом рынке на основе теории нелинейного отображения многомерных данных. В рамках теории функционирования искусственных нейронных сетей, рассмотрена гибкость исследуемого подхода, с той точки зрения, что многослойный перцептрон с любой архитектурой (любое количество слоев) способен решать заявленный класс задач.

В работе рассмотрены и подробно описаны все этапы построения конечной нейросетевой модели: выбор эмпирической базы, определение начального массива данных, выявление релевантной статистически значимой информации на основе метода главных компонент и метода снижения корреляции, описаны и обоснованы принципы выбора основных характеристик сети (активационная функция, алгоритм настройки весов и т.д.).

В рамках данного исследования было установлено, что существует корреляция между размером входных данных для нейронной сети и величиной качества прогнозирования. Причем, для всех финансово-биржевых инструментов наблюдается одинаковая тенденция роста/снижения точности прогноза на всех участках изменения размера «скользящего окна».

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- 1) Головачев, С.С. Прогнозирование доходности на фондовом и валютном рынках на основе моделей искусственных нейронных сетей: дис. к.э.н.: 08.00.10: Защищена 07.10.2014: Сергей Сергеевич Головачев; науч.рук. д.э.н. Е.В.Рубенович. Москва, 2014. 191 с.
- 2) Ежов, А.А. Нейрокомпьютинг и его применения в экономике и бизнесе / А.А. Ежов, С.А. Шумский // М.: МИФИ, 1998. 224 с.
- 3) Эконометрика [Электронный ресурс]: Education Library: on-line библиотека электронных учебных пособий. URL: http://edulib.pgta.ru/edudata/prmat/4_econometry/soder/all.htm (дата обращения 06.06.2016). Загл. с экрана. Яз. рус.
- 4) Миркес, Е. М. Логически прозрачные нейронные сети и производство явных знаний из данных // Нейроинформатика / Е.М. Миркес, А. Н. Горбань, В. Л. Дунин-Барковский, А. Н. Кирдин и др. // Новосибирск: Наука. Сибирское предприятие РАН. 1998. 296 с.
- 5) Фармацевтический рынок России. Выпуск: сентябрь 2017 года DSM Group. СМК соответствует требованиям ISO 9001:2008. 27 с.