

Министерство науки и высшего образования Российской Федерации
 федеральное государственное автономное
 образовательное учреждение высшего образования
 «Национальный исследовательский Томский политехнический университет» (ТПУ)

Школа Инженерная школа ядерных технологий

Направление подготовки 01.04.02 «Прикладная математика и информатика»

Отделение школы (НОЦ) экспериментальной физики

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

Тема работы

Прогнозирование финансовых временных рядов с использованием нейронных сетей

УДК 519.246:336:004.7.032.26

Студент

Группа	ФИО	Подпись	Дата
ОВМ81	Булыкина Анастасия Александровна		

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Шинкеев М.Л.	к. ф.-м. н., доцент		

КОНСУЛЬТАНТЫ ПО РАЗДЕЛАМ:

По разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Киселева Е.С.	к. э. н., доцент		

По разделу «Социальная ответственность»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Старший преподаватель	Романова С.В.	—		

ДОПУСТИТЬ К ЗАЩИТЕ:

Руководитель ООП	ФИО	Ученая степень, звание	Подпись	Дата
Профессор	Трифонов А.Ю.	д. ф.-м. н., профессор		

ЗАПЛАНИРОВАННЫЕ РЕЗУЛЬТАТЫ ОБУЧЕНИЯ

Код	Результаты обучения
<i>Общепрофессиональные компетенции</i>	
P1	Самостоятельно приобретать, развивать и применять математические, естественнонаучные, социально-экономические и профессиональные знания для решения нестандартных задач, в том числе в новой или незнакомой среде и в междисциплинарном контексте.
P2	Владеть и применять методы и средства получения, хранения, переработки и трансляции информации посредством современных компьютерных технологий, в том числе в глобальных компьютерных сетях.
P3	Демонстрировать культуру мышления, способность выстраивать логику рассуждений и высказываний, основанных на интерпретации данных, интегрированных из разных областей науки и техники, выносить суждения на основании неполных данных, анализировать профессиональную информацию, выделять в ней главное, структурировать, оформлять и представлять в виде аналитических обзоров с обоснованными выводами и рекомендациями.
P4	Анализировать и оценивать уровни своих компетенций в сочетании со способностью и готовностью к саморегулированию дальнейшего образования и профессиональной мобильности. Владеть, по крайней мере, одним из иностранных языков на уровне социального и профессионального общения, применять специальную лексику и профессиональную терминологию языка. Демонстрировать способность к самостоятельному обучению новым методам исследования, способность самостоятельно приобретать с помощью информационных технологий и использовать в практической деятельности новые знания и умения.
P5	Использовать на практике умения и навыки в организации исследовательских работ по использованию математических методов и моделирования для решения задач, способность организовывать и руководить работой команды.
P6	Совершенствовать и развивать свой интеллектуальный и общекультурный уровень. Проявлять инициативу, в том числе в ситуациях риска, брать на себя всю полноту ответственности.
<i>Профиль «Математические методы в экономике»</i>	
P9	Разрабатывать стратегии и цели проектирования, критерии эффективности и ограничения применимости, новые методы, средства и технологии использования математических методов в экономике, науке и технике
P10	Планировать и проводить теоретические исследования и компьютерные эксперименты при использовании математических методов в экономике, науке и технике

Министерство образования и науки Российской Федерации
федеральное государственное автономное образовательное учреждение
высшего образования
**«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ПОЛИТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ»**

Инженерная школа ядерных технологий

Направление подготовки 01.04.02 «Прикладная математика и информатика»

Отделение экспериментальной физики

УТВЕРЖДАЮ:

Руководитель ООП

_____ Трифонов А.Ю.

(Подпись) (Дата) (Ф.И.О.)

ЗАДАНИЕ

на выполнение выпускной квалификационной работы

В форме:

Магистерской диссертации

Студенту:

Группа	ФИО
ОВМ81	Булыкина Анастасия Александровна

Тема работы:

Прогнозирование финансовых временных рядов с использованием нейронных сетей

Утверждена приказом директора (дата, номер)

28.02.2020, № 59-75/с

Срок сдачи студентом выполненной работы:

31.05.2020

ТЕХНИЧЕСКОЕ ЗАДАНИЕ:

Исходные данные к работе

(наименование объекта исследования или проектирования; производительность или нагрузка; режим работы (непрерывный, периодический, циклический и т. д.);

Ежедневные цены закрытия (Close) акций компаний «Сбербанк» (SBER) и «Газпром» (GAZP). Источником данных является информационный портал Finam.ru.

<p>Перечень подлежащих исследованию, проектированию и разработке вопросов</p> <p><i>(аналитический обзор по литературным источникам с целью выяснения достижений мировой науки техники в рассматриваемой области; постановка задачи исследования, содержание процедуры исследования, проектирования, конструирования; заключение по работе).</i></p>	<ol style="list-style-type: none"> 1. Проанализировать существующие нейросетевые методы, используемые для прогнозирования финансовых временных рядов; 2. Выбрать оптимальную нейронную сеть; 3. Качественно подготовить исходные данные для построения нейронных сетей; 4. Построить прогноз цен закрытия акций компании «Сбербанк» для задач регрессии и двухзначной классификации (Рост/Спад), используя нейронные сети различной структуры; 5. На основании построенных прогнозов сделать вывод о возможности применения нейронных сетей рассматриваемой архитектуры для прогнозирования финансовых временных рядов.
---	--

<p>Перечень графического материала</p> <p><i>(с точным указанием обязательных чертежей)</i></p>	<p>Мультимедийная презентация:</p> <ul style="list-style-type: none"> • Цель и задачи работы • Объект и методы исследования • Представление исходных данных • Математическая модель нейрона • Используемые функции активации • Выбор типа нейронной сети для прогнозирования • Результаты исследования для задач класса «Регрессия», MLP 20–4–1 • Результаты исследования для класса задач «Регрессия», MLP 6-3-1 • Вычисление ошибки прогноза и сравнение построенных моделей прогнозирования: AR (1) и MLP 20-4-1 и MLP 6-3-1 • Результаты исследования для класса задач класса «Классификация» • Заключение • Список публикаций
--	--

Консультанты по разделам выпускной квалификационной работы	
Раздел	Консультант
Финансовый менеджмент, ресурсоэффективность и ресурсосбережение	Киселева Е.С.
Социальная ответственность	Романова С.В.
Раздел на иностранном языке	Смирнова У.А.

Дата выдачи задания на выполнение выпускной квалификационной работы по линейному графику	15.03.2020
---	------------

Задание выдал руководитель:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Шинкеев М.Л.	к.ф.-м.н., доцент		

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
0ВМ81	Булыкина Анастасия Александровна		

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА
«ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И
РЕСУРСОСБЕРЕЖЕНИЕ»**

Студенту:

Группа	ФИО
0ВМ81	Булькиной Анастасии Александровне

Школа	ИЯТШ	Отделение школы (НОЦ)	ОЭФ
Уровень образования	Магистратура	Направление/специальность	01.04.02 Прикладная математика и информатика

Исходные данные к разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»:	
1. <i>Стоимость ресурсов научного исследования (НИ): материально-технических, энергетических, финансовых, информационных и человеческих</i>	<i>Стоимость материальных ресурсов определялась в соответствии с рыночными ценами г. Томска. Тарифные ставки исполнителей определены штатным расписанием НИ ТПУ.</i>
2. <i>Нормы и нормативы расходования ресурсов</i>	<i>Коэффициенты для расчета заработной платы</i>
3. <i>Используемая система налогообложения, ставки налогов, отчислений, дисконтирования и кредитования</i>	<i>Коэффициент отчислений во внебюджетные фонды – 30,2 %.</i>

Перечень вопросов, подлежащих исследованию, проектированию и разработке:	
1. <i>Оценка коммерческого и инновационного потенциала НТИ</i>	<i>1. Потенциальные потребители результатов исследования; 2. SWOT – анализ; 3. Оценка готовности проекта к коммерциализации.</i>
2. <i>Разработка устава научно-технического проекта</i>	<i>1. Постановка цели, ожидаемых результатов проекта; 2. Определение внутренних и внешних заинтересованных сторон проекта; 3. Определение ограничений/допущений проекта.</i>
3. <i>Планирование процесса управления НТИ: структура и график проведения, бюджет, риски и организация закупок</i>	<i>1. Определение структуры и трудоемкости выполнения работ; 2. Бюджет научно - технического исследования (НТИ); 3. Реестр рисков проекта.</i>

Перечень графического материала (с точным указанием обязательных чертежей):	
<ol style="list-style-type: none"> 1. Сегментирование рынка (табл. 7) 2. Матрица SWOT (табл. 8) 3. Оценка готовности проекта к коммерциализации (табл. 9) 4. Заинтересованные стороны (табл. 10) 5. Цели и результат проекта (табл.11) и рабочая группа проекта (табл. 12) 6. Ограничения/допущения проекта (табл.13) 7. Иерархическая структура работ проекта (рис.22) 8. Комплекс работ по разработке проекта (табл.14) 9. Временные показатели осуществления комплекса работ (табл.15) 10. Календарный план-график выполнения работ (диаграмма Гантта) (табл. 16) 11. Расчёт бюджета исследования (табл. 17-21) 12. Реестр рисков (табл. 22) 	

Дата выдачи задания для раздела по линейному графику	
---	--

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОГСН ШБИП	Киселева Е.С.	К. Э. Н.		15.03.2020

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
0ВМ81	Булькина Анастасия Александровна		15.03.2020

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА
«СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ»**

Студенту:

Группа	ФИО
ОВМ81	Булькиной Анастасии Александровне

Школа	ИЯШТ	Отделение (НОЦ)	ОЭФ
Уровень образования	Магистратура	Направление/специальность	01.04.02 Прикладная математика и информатика

Исходные данные к разделу «Социальная ответственность»:

1. Характеристика объекта исследования (вещество, материал, прибор, алгоритм, методика, рабочая зона) и области его применения	<ul style="list-style-type: none"> – Объект исследования: финансовые временные ряды. – Область применения: фондовые рынки. Научно-техническое исследование, проведённое в данной работе, имеет непосредственное отношение к инвестициям. Потенциальными потребителями результатов исследования могут быть: инвесторы, владеющие акциями; банки; банковские организации.
Перечень вопросов, подлежащих исследованию, проектированию и разработке:	
1. Правовые и организационные вопросы обеспечения безопасности: <ul style="list-style-type: none"> – специальные (характерные при эксплуатации объекта исследования, проектируемой рабочей зоны) правовые нормы трудового законодательства; – организационные мероприятия при компоновке рабочей зоны. 	<ul style="list-style-type: none"> – ГОСТ 12.1.038-82 ССБТ; – СанПиН 2.2.2/2.4.1340-03; – ГОСТ 12.2.032-78 ССБТ. – СН 245-78.
2. Производственная безопасность: 2.1. Анализ выявленных вредных и опасных факторов 2.2. Обоснование мероприятий по снижению воздействия	<ol style="list-style-type: none"> 1. Отклонение показателей микроклимата; 2. Недостаточная освещённость рабочей зоны; 3. Превышение уровня шума; 4. Повышенный уровень электромагнитных излучений 5. Повышенное значение напряжение в электрической цепи, замыкание которой может произойти через тело человека; 6. Психофизические факторы.
3. Экологическая безопасность:	<ul style="list-style-type: none"> – анализ воздействия при работе на ПЭВМ на атмосферу, гидросферу, литосферу; – наличие отходов (бумага, картриджи, компьютеры и т.д.); – методы утилизации отходов.
4. Безопасность в чрезвычайных ситуациях:	<ul style="list-style-type: none"> – выявление типичных аварийных ситуаций: сильных морозов, несанкционированного проникновения посторонних лиц; – разрабатываются превентивные меры по предупреждению ЧС; – разработка действий в результате возникшей ЧС и мер по ликвидации её последствий.

Дата выдачи задания для раздела по линейному графику	17.02.2020
---	------------

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Старший преподаватель	Романова С.В.	–		

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
ОВМ81	Булькина Анастасия Александровна		

Реферат

Пояснительная записка к научно-исследовательской работе выполнена на 116 страницах машинописного текста, содержит 24 таблицы, 24 рисунка, 26 источников и 3 приложения.

Ключевые слова: Нейронная сеть, многослойный персептрон, прогнозирование, финансовые временные ряды, ошибка прогноза.

Объект исследования: нейросетевые модели, которые используются при прогнозировании финансовых временных рядов.

Цель работы – прогнозирование цен закрытия акций компании «Сбербанк» с использованием нейронных сетей.

Разработан подход к проблеме прогнозирования, в основе которого лежат нейросетевые методы. Они отличаются своей способностью устанавливать нелинейные связи между будущими и фактическими значениями и хорошей масштабируемостью. В работе была определена архитектура нейронной сети и оптимизированы параметры сети. Используя многослойный персептрон и алгоритм обучения BFGS, в среде STATISTICA 10.0 были построены нейронные сети, позволяющие получить краткосрочные прогнозы котировок ценных бумаг на фондовом рынке для задач регрессии и классификации.

Степень внедрения: средняя; результаты данной работы могут быть использованы для прогнозирования финансовых временных рядов методом двухзначной классификации (Рост/Спад).

Область применения: фондовый рынок: инвесторы, владеющие акциями; банки; банковские организации. Также данными исследованиями могут воспользоваться государственные учреждения, интернет-ресурсы и другие связанные с финансовыми инвестициями организации.

Оглавление

Введение	10
1. Теоретическая часть научно-технического исследования.....	12
1.1. Технический и фундаментальный анализ рынка ценных бумаг	12
1.2. Введение в теорию нейронных сетей	13
1.3. Структура сети.....	14
1.4. Топологии нейронных сетей	17
1.5. Обучение нейронной сети	19
2. Применение нейронных сетей в задачах прогнозирования	24
2.1. Этапы нейросетевого предсказания финансовых временных рядов	24
2.2. «Метод окон».....	26
3. Практическая часть научно-технического исследования	28
3.1. Прогнозирование цен закрытия акций Сбербанка с использованием нейронных сетей в программе STATISTICA	28
3.2. Выбор программного продукта для прогнозирования финансовых временных рядов с использованием нейронных сетей.....	30
3.3. Исследуемые выборки.....	31
3.4. Предобработка данных для прогнозирования финансовых временных рядов с использованием нейронных сетей	33
3.5. Выбор типа нейронной сети.....	34
3.6. Прогнозирование котировок Сбербанка с помощью авторегрессионных моделей	38
3.7. Прогнозирование котировок Сбербанка с использованием нейронных сетей (Регрессия).....	41
3.8. Прогнозирование котировок Сбербанка с использованием нейронных сетей (Классификация).....	48
3.9. Результаты проведенного исследования	52
4 Финансовый менеджмент, ресурсоэффективность и ресурсосбережение... 54	54
4.1 Предпроектный анализ.....	54
4.1.1 Потенциальные потребители результатов исследования	54
4.1.2 SWOT-анализ	56
4.1.3 Оценка готовности проекта к коммерциализации.....	57
4.1.4 Методы коммерциализации результатов научно-технического исследования.....	59

4.2	Инициация проекта.....	60
4.2.1	Организационная структура проекта	61
4.2.2	Ограничения и допущения проекта.....	62
4.3	Планирование научно-исследовательских работ	62
4.3.1	Иерархическая структура работ проекта	62
4.3.2	Структура работ в рамках научного исследования	63
4.3.3	Определение трудоемкости выполнения работ и разработка графика проведения научного исследования.....	64
4.3.4	Бюджет научно-технического исследования	69
4.4	Реестр рисков проекта	74
4.5	Выводы по разделу	74
5.	Социальная ответственность	77
5.1	Правовые и организационные вопросы обеспечения безопасности	78
5.2	Производственная безопасность	80
5.3	Анализ опасных и вредных производственных факторов	81
5.3.1	Отклонение показателей микроклимата	81
5.3.2	Недостаточная освещённость рабочей зоны	83
5.3.3	Превышение уровня шума	86
5.3.4	Повышенный уровень электромагнитных излучений	87
5.3.5	Повышенное значение напряжение в электрической цепи, замыкание которой может произойти через тело человека.....	88
5.3.6	Психофизиологические факторы.....	89
5.4	Экологическая безопасность.....	90
5.5	Безопасность в чрезвычайных ситуациях	90
5.6	Выводы по разделу	92
5.7	Перечень научно-технической документации	93
	Заключение	94
	Список публикаций студента.....	96
	Список используемых источников	100
	Приложение А	102
	Приложение Б.....	103
	Приложение В.....	104

Введение

Искусственные нейронные сети (ИНС) имеют широкое распространение среди различного рода прикладных задач, таких как сжатие данных, распознавание образов, оптимизация, анализ данных, задачи управления и др. Одним из важнейших направлений практического использования ИНС являются задачи прогнозирования, а именно задачи прогнозирования временных рядов на фондовом рынке, предсказание курса валют, построение прогноза потребления электроэнергии, прогнозирование платежеспособности кредиторов, нагрузок энергетических систем и пр. Мы видим, что ИНС могут применяться для решения практически любого рода задач, в том числе и при отсутствии явной математической модели или недостатке данных для эффективного применения статистических методов.

Нетривиальной задачей является прогноз поведения сложных динамических систем. Как правило, такой прогноз основывается на обнаружении скрытых закономерностей в накопленных данных. Одним из примеров задач такого рода может служить прогнозирование финансовых временных рядов. Коллективная психология участников торгов имеет непосредственное влияние на формирование биржевой цены, усложняя данный процесс, зато имеются накопленные данные в виде финансового временного ряда.

Актуальность диссертационного исследования заключается в использовании нейронных сетей для решения трудноформализуемой задачи прогнозирования финансовых временных рядов, а также важностью получения качественных прогнозов основных финансовых индикаторов в условиях рыночной экономики.

В данной работе для решения задачи прогнозирования финансовых временных рядов рассмотрены нейросетевые методы, которые отличаются от других моделей своей способностью устанавливать нелинейные связи между будущими и фактическими значениями и хорошей масштабируемостью.

Цель работы – прогнозирование цен закрытия акций компании

«Сбербанк» с использованием нейронных сетей. Построенная нейронная сеть должна быть оптимальной по внутренней структуре и способу управления потоками информации между нейронами. Для решения практической задачи будем использовать выбранную нейросетевую модель.

Объект исследования: нейросетевые модели, которые используются при прогнозировании финансовых временных рядов.

Для достижения поставленной цели необходимо решить следующие **задачи:**

1. Проанализировать существующие нейросетевые методы, используемые для прогнозирования финансовых временных рядов;
2. Выбрать оптимальную нейронную сеть;
3. Качественно подготовить исходные данные для построения нейронных сетей;
4. Построить прогноз цен закрытия акций компании «Сбербанк» для задач регрессии и двухзначной классификации (Рост/Спад), используя нейронные сети различной структуры;
5. На основании построенных прогнозов сделать вывод о возможности применения нейронных сетей рассматриваемой архитектуры для прогнозирования финансовых временных рядов.

Период исследования: Ежедневные цены закрытия (Close) акций компании «Сбербанк» (SBER) за периоды:

1. 2019 г.
2. с января 2016 г. по январь 2019 г.

Источником данных является информационный портал Finam.ru. Для проведения расчетов и построения нейросетевых моделей был использован программный пакет STATISTICA (ST), программный модуль – ST Neural Networks.

1. Теоретическая часть научно-технического исследования

1.1. Технический и фундаментальный анализ рынка ценных бумаг

При инвестировании денежных средств ключевой задачей является попытка отыскать финансовые инструменты, направленные либо на увеличение, либо, в крайних случаях, сохранение собственных вложений. Пытаясь предсказать будущее, крупные инвесторы используют разные методы для определения динамики развития рынка.

Среди огромного множества математических методов анализа фондовых рынков [1-3] наибольшей популярностью пользуются фундаментальный и технический анализы.

В основе фундаментального анализа лежит независимая оценка действительной стоимости ценных бумаг, основанная на изучении экономических факторов, связанных с ними. Для определения величины отклонения проводится сравнение действительной и текущей стоимостей. Фундаментального анализа бывает недостаточно для определения конкретного момента совершения сделки. В таком случае прибегают к использованию технического анализа.

Данный вид анализа основывается на утверждении, что в текущей цене акции уже включены все объективные данные об эмитенте. Таким образом, полагают, что динамика рыночной стоимости акции зависит только от оценки событий участниками рынка, а не является непосредственной реакцией на события [4].

Оба метода являются дополнением друг друга, и в равной степени показывают состояние фондового рынка.

Технический анализ – это общепринятый подход при исследовании рынка, цель которого – прогнозирование. Данный анализ предполагает, что рынок имеет свойство «запоминать» информацию. Это значит, что на будущее движение стоимости ценных бумаг существенно влияют закономерности её прошлого поведения. Другими словами, рынок может «запомнить», как себя

вести в той или иной ситуации, и в следующий раз её воспроизвести.

Технический анализ все чаще используется в прогнозировании, что подтверждается ростом его популярности в последние 10 лет. Индикаторы поведения рынка являются основой эмпирических правил технического анализа. Технический анализ рассматривает финансовый инструмент индивидуально без учета его связи с другими ценными бумагами [4]. Субъективность и плохое прогнозирование направления цен (правый край графика) являются недостатками данного вида анализа. В связи с этим, нейросетевой анализ начинает постепенно вытеснять этот вид анализа, так как в нем отсутствуют ограничения на характер входной информации.

Нейросетевое моделирование базируется на данных, без учета и привлечения априорных соображений. Это обстоятельство является одновременно и достоинством, и недостатком метода. Например, существует вероятность, что имеющихся данных может не хватить для обучения, размерность потенциальных входов может оказаться слишком велика.

Поэтому для хорошего прогноза, во-первых, данные должны пройти качественную предобработку, а во-вторых, нужно использовать нейропакеты с широкой функциональностью.

1.2. Введение в теорию нейронных сетей

Параллельно распределенную структуру обработки информации, состоящую из взаимосвязанных нейронов, называют *нейронной сетью*.

Как мощный метод моделирования, данные сети способны воспроизводить сложные нелинейные зависимости. Моделирование нелинейных процессов, адаптивность и способность работы с зашумленными данными позволяют использовать нейросети в решении многих экономических задач.

Ускорение процесса обработки информации за счет параллельности работы всех звеньев является одной из важнейших особенностей нейронной сети, открывающей ее потенциал и широкие возможности использования. Кроме того, данная сеть за счет большого числа межнейронных соединений,

имеет устойчивость к ошибкам, которые возникают на некоторых линиях.

Обобщение накопленных знаний и способность к обучению также одни из важных свойств нейросети. Таким образом, нейросеть по своим чертам похожа на искусственный интеллект. Такая сеть, натренированная на определенном множестве данных, может провести обобщение полученной информации и воспроизвести расчет с хорошими результатами на данных, не использованных при её обучении.

1.3. Структура сети

В нейронной сети единицей обработки информации является нейрон. Нейрон имеет следующую модель строения, похожую на биологический нейрон: дендриды, представляющие собой каналы для ввода информации, и аксон, являющийся каналом вывода информации.

Для соединения аксона нейрона с дендридами других нейронов используются синапсы. Возбуждение нейрона приводит к передаче сигнала вдоль аксона. Синапс передает сигнал на другие нейроны, что приводит либо к их возбуждению, либо к переходу в состояние торможения. Возбуждение нейрона возникает только в случае преодоления порога возбуждения или активации. Таким образом, сумма уровней сигналов, поступающих в нейрон, должна быть выше этого уровня.

Нейрон, лежащий в основе искусственной нейросети, может быть представлен в виде модели, показанной на рисунке 1.

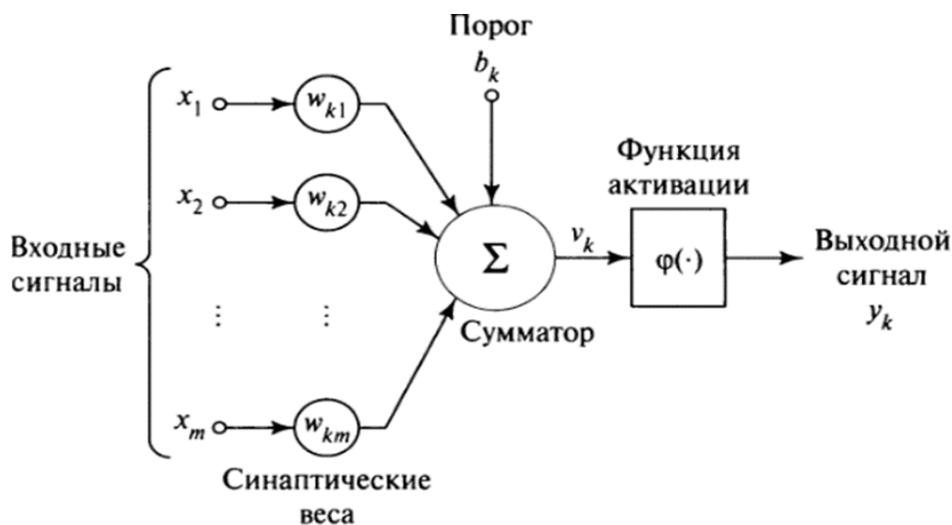


Рисунок 1 – Модель нейрона

Согласно представленному рисунку, нейроны имеют входные каналы, через которые поступают сигналы x_i на вход нейрона. Каждый канал имеет соединение, обладающее определенной силой и весом w_{ki} . Данные коэффициенты w_{ki} являются весами синаптических связей. Если синапс является возбуждающим, то коэффициент w_{ki} имеет положительное значение, при отрицательном значении синапс является тормозящим. Если $w_{ki} = 0$ то говорят об отсутствии связи между нейронами k и i . Поступивший сигнал преобразуется в сумматоре, происходит добавление порога b_k , функция φ преобразует результат, далее происходит подача на выход нейрона. Функционирование нейрона описывается в математическом виде при помощи следующей пары уравнений:

$$v_k = \sum_{i=1}^m w_{ki} x_i$$

где w_{ki} – синаптические веса нейрона k ;

x_i – входные сигналы;

$$y_k = \varphi(v_k + b_k)$$

где φ – функция активации;

v_k – линейная комбинация входных воздействий;

b_k – порог активации.

Преобразование сигнала, полученного нейронами, в выходной сигнал $y_k = \varphi(v_k)$. осуществляется при нелинейной функции активации φ . Данная функция является нелинейной функцией и используется для моделирования процесса передачи возбуждения.

Существует большое количество функций активации, самыми часто используемыми функциями активации являются: функция единичного скачка, сигмоидальная функция, функция гиперболического тангенса, кусочнолинейная функция и функция знак. Логистическая функция является примером сигмоидальной функции активации и является наиболее часто

используемой для прогнозирования:

$$\varphi(v) = \frac{1}{1 + e^{-av}}$$

где a – параметр наклона сигмоидальной функции;

v – линейная комбинация входных воздействий.

На рисунке 2 представлен диапазон от 0 до 1, в котором сигмоидальная функция способна принимать бесконечное множество значений.

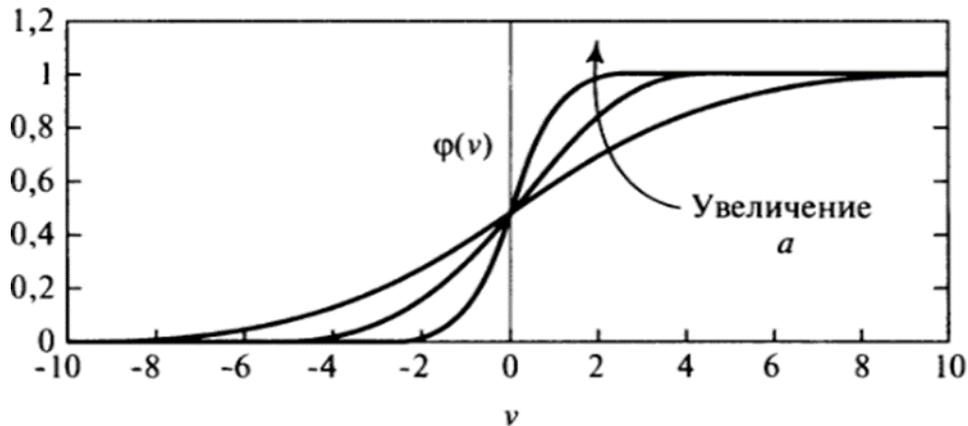


Рисунок 2 – график сигмоидальной функции

Эта функция принимает числовое значение на входе и выдает на выходе числовое значение в интервале от 0 до 1. Большие по модулю отрицательные числа превращаются в ноль, а большие положительные числа превращаются в 1. Логистическая функция активации широко используется, поскольку ее выходной сигнал хорошо интерпретируется как уровень активации нейрона: от отсутствия активации – ноль, до полностью насыщенная активация – единица.

Ещё одним примером сигмоидальной функции является гиперболический тангенс. В данном случае выходные значения лежат в интервале $(-1, +1)$. По сравнению с логистической гиперболическая функция гиперболического тангенса часто дает лучшие результаты, благодаря своему свойству симметрии.

Построение искусственной нейронной сети основано на взаимосвязанных нейронах. Вычислительные возможности нейронной сети связаны с архитектурой сети, то есть организацией нейронов и их связей.

Классификация нейронных сетей на основе их архитектуры представлена на следующих рисунках: полносвязные сети (рис. 3-а), многослойные сети (рис. 3-б), слабосвязные сети (нейронные сети с локальными связями) (рис. 3-в).

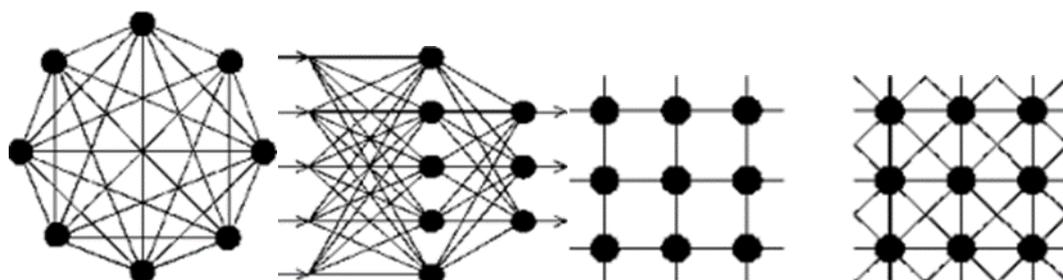


Рисунок – 3-а

Рисунок – 3-б

Рисунок – 3-в

1.4. Топологии нейронных сетей

При топологической классификации нейронных сетей выделяют две группы сетей: сети прямого распространения и рекуррентные сети.

1. Сети прямого распространения.

Расположение нейронов по слоям характерно для многослойных нейронных сетей. В таких сетях поступающий на нейроны первого слоя сигнал после преобразования передается на нейроны второго слоя, на втором случае протекают те же процессы преобразования и передачи на последующие слои и на последнем k -ном слое происходит выдача выходных данных. Сети подобного рода называются многослойными сетями прямого распространения. Слои, находящиеся в промежутке между входным сигналом и слоем выходного сигнала, называются скрытыми слоями (рис. 4.) Выделяют полносвязные и неполносвязные многослойные сети. Для полносвязных сетей характерно связывание всех узлов каждого слоя с узлами смежных слоев. Неполносвязная сеть характеризуется отсутствием некоторых синаптических связей.

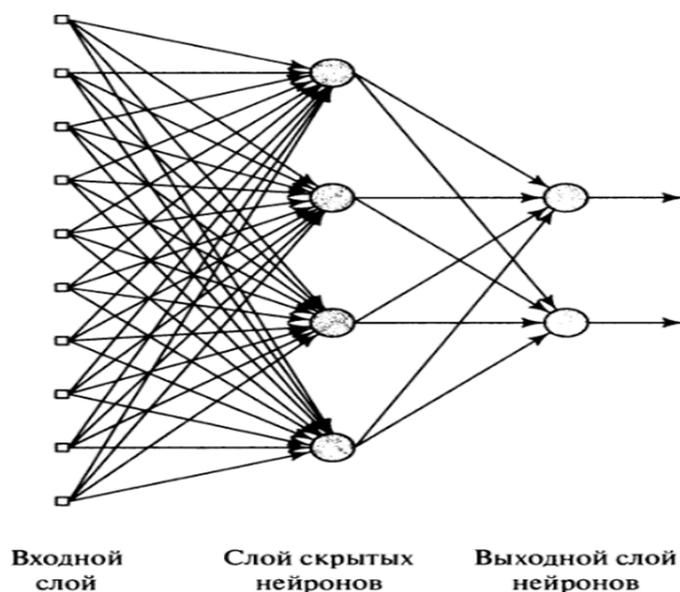


Рисунок 4 – Многослойная полносвязная сеть прямого распространения с одним скрытым слоем

Сети прямого распространения универсальны для аппроксимации, но не существует правила, которое позволит найти оптимальную топологию для данной задачи.

2. Рекуррентные сети.

Отличием рекуррентных сетей является наличие обратных связей, которые влияют на способность к обучению и увеличению производительности сети [5]. С точки зрения проведения теоретических исследований данные сети привлекли огромный интерес исследователей, но с практической точки зрения они значительно уступают по полезным свойствам сетям прямого распространения.

При выборе топологии (структуры) нейросети необходимо опираться на сложность и особенность поставленной задачи. Типичные и наиболее часто используемые архитектуры нейронных сетей показаны на рисунке 5 [6].

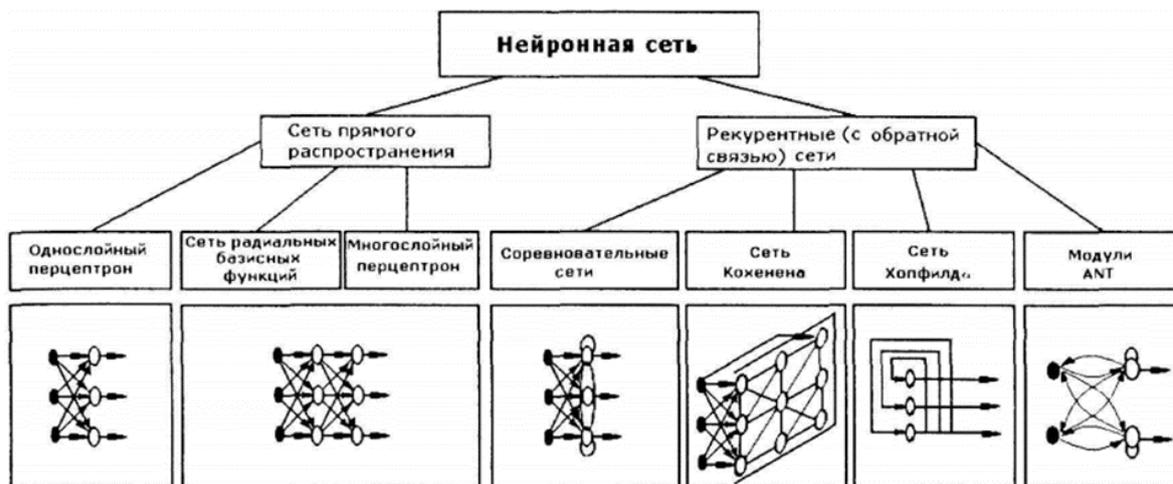


Рисунок 5 – Архитектуры нейронных сетей

В 1957 г. Колмогоров предложил теорему, согласно которой любая непрерывная функция из n аргументов на единичном кубе $[0,1]^n$ представима в виде суперпозиции непрерывных функций одного аргумента и операции «+»:

$$f(x^1, x^2, \dots, x^n) = \sum_{k=1}^{2n+1} h_k \left(\sum_{i=1}^n \varphi_{ik}(x^i) \right)$$

Функция активации скрытого нейрона
 Скрытый слой нейронов
 Входной слой нейронов
 Функции синаптической связи
 Двухслойная нейронная сеть описывает почти любую функцию

1.5. Обучение нейронной сети

Перед решением конкретной задачи сеть должна пройти обучение. *Обучением* называется процесс адаптации сети к внешним воздействиям путем подгонки внутренних параметров. Как правило, такой процесс является итеративным, и включает в себя определенные шаги, которые называются эпохами (циклами).

В каждом цикле обучения сети вычисляют синаптические коэффициенты w_{ki} . Расчет этих коэффициентов основан на группе примеров, так называемых обучающих множествах или обучающей выборке. В составе такого множества лежат данные, имеющие заданное желаемое значение выходного параметра. При таком обучении на вход сети подается вектор исходных данных, и выходной узел должен сообщить значение результата,

которое нам необходимо. Весь процесс называют контролируемым обучением (обучение с учителем), и может быть рассмотрен как решение задачи оптимизации. Разность, возникающая между откликом и правильным решением, так называемая ошибка, может быть уменьшена через настройку свободных параметров. При этом, корректировка сети с целью минимизирования ошибки не дает полной уверенности в ее уменьшении [7].

Это связано со сложным строением поверхности ошибки и наличием таких неприятных свойств, как локальные минимумы, седловые точки, длинные узкие овраги и плоские участки. Определение положения глобального минимума на поверхности ошибок при помощи аналитических методов невозможно, поэтому обучение нейросети состоит, по сути, в исследовании этой поверхности. Достижение в результате обучения глобального минимума называют сходимостью процесса обучения. Алгоритмов для обучения нейронной сети в настоящее время насчитывают больше ста. Отличие существующих алгоритмов основано на стратегии оптимизации и критериях ошибок. Нередко мерой ошибки является среднеквадратичная ошибка E . Она определяется как сумма квадратов между желаемыми выходными значениями и реально полученными сетью значениями y_k :

$$E = \frac{1}{P} \sum_{k=1}^p (d_k - y_k)^2$$

где P – число примеров в обучающем множестве;

d_k – желаемая величина выхода;

y_k – значения, полученные на сети.

При обучении нейронной сети с прямой связью часто используют алгоритм обратного распространения ошибки. В основе данного алгоритма лежит вычисление градиента поверхности ошибок, который определяет направление кратчайшего спуска по поверхности из заданной точки. После ряда итераций последовательность шагов позволяет определить этот минимум. Одной из трудностей метода является подбор длины шага. Большая

длина шага имеет быструю сходимость, но в некоторых случаях, например, если поверхность имеет форму узкого оврага, есть вероятность «перескока» через решение. Маленькая длина шага позволяет задать правильное направление продвижения, но достижение минимума наступает через достаточно большое количество итераций. При практическом расчете величина шага пропорциональна крутизне склона с постоянной, которая называется скоростью обучения.

Таким образом, алгоритм обратного распространения ошибки представляет собой алгоритм градиентного спуска, минимизирующий квадратичную ошибку E :

$$E = \frac{1}{2} \sum_{k=1}^p \sum_i (d_k^i - y_k^i)^2$$

i – индекс, проходящий через все выходы многослойной сети.

Каждая эпоха включает следующую последовательность действий:

- подача на вход сети обучающих наблюдений;
- сравнение выходных и целевых значений;
- вычисление ошибки;
- корректировка весов;
- повторение всех действий.

Обучение завершают, если достигнуто определенное количество эпох, при достижении ошибкой некоторого уровня или прекращение уменьшения ошибки.

Минимизирование ошибки на обучающем множестве и минимизирование «настоящей» ошибки на поверхности ошибки различны, в этом и кроется опасность данного метода. Особенно эта разница заметна при переобучении или излишней подгонке.

Выделяют два основных режима обучения:

- ❖ Последовательный (пример указан выше)
 - Одиночное пропускание обучающих объектов через сеть

- Корректировка весов для каждого объекта

❖ Пакетный

- Корректировка весов осуществляется после того, как всё обучающее множество прошло через сеть

$$\Delta w_{ji}(n) = -\eta \frac{\partial E_{av}}{\partial w_{ji}} = -\eta \sum_{n=1}^N e_j(n) \frac{\partial e_j(n)}{\partial w_{ji}}$$

В своей работе мы обучали сеть с помощью алгоритма обучения *Квази-Ньютона (BFGS)*. Данный алгоритм использует пакетный режим обучения. Основной идеей является разложение функции сходимости до 2-го порядка в точке w_n :

$$\Delta E(w(n)) = E(w(n+1)) - E(w(n)) = g^T(n)\Delta w(n) + \frac{1}{2}\Delta w^T(n)H(n)\Delta w(n)$$

где $H(n)$ – матрица Гессе.

- Задаем необходимое условие оптимальности:

$$g(n) + H(n)\Delta w(n) = 0$$

- Отсюда алгоритм Ньютона примет следующий вид:

$$w(n+1) = w(n) + \Delta w(n) = w(n) - H^{-1}(n)g(n)$$

Так как вычисление матрицы Гессе является сложным процессом, то для решения этой проблемы необходимо построить итерационное приближение к обратной матрице Гессе по алгоритму BFGS (Бройдена-Флетчера-Гольдфарба-Шанно). Весь этот процесс и называют итерационным алгоритмом Квази-Ньютона.

Пусть имеется задача оптимизации функционала, которую мы будем решать в алгоритме BFGS:

$$\min_{x \in R^n} f(x)$$

где функция $f: R^n \rightarrow R$ является достаточно гладкой.

Методы второго порядка основаны на итерациональном решении данной задачи через разложение функции в полином второй степени:

$$f(x_k + p) = f(x_k) + \nabla f^T(x_k)p + \frac{1}{2}p^T H(x_k)p,$$

где H — гессиан функционала f в точке x .

Определитель матрицы $H(f)$ — определитель Гессе, или гессиан:

$$H(f) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$$

Вычисление гессиана является достаточно трудоемким процессом. BFGS алгоритм решает эту проблему путем вычисления приближенного значения B_k взамен настоящего значения $H(x)$. Нахождение минимума полученной квадратичной задачи проводится по формуле:

$$p_k = -B_k^{-1} \nabla f(x_k).$$

Далее происходит поиск вдоль данного направления точки a_k , для которой должны выполняться условия Вольфе:

$$\begin{aligned} f(x_k - a_k p_k) &\leq f(x_k) + c_1 a_k \nabla f_k^T p_k, \\ \nabla f(x_k - a_k p_k)^T p_k &\geq c_2 \nabla f_k^T p_k, \end{aligned}$$

Выбор констант происходит следующим образом: $0 < c_1 < c_2 < 1$.

Начальным приближением гессиана может быть любая невырожденная, хорошо обусловленная матрица (чаще всего единичная). Для вычисления приближенного значения гессиана на следующем шаге используют формулу:

$$B_{k+1} = B_k - \frac{B_k s_k s_k^T B_k}{s_k^T B_k s_k} + \frac{y_k y_k^T}{y_k^T s_k},$$

где I — единичная матрица, $s_k := x_{k+1} - x_k$ — шаг алгоритма на итерации, $y_k := \nabla f(x_{k+1}) - \nabla f(x_k)$ — изменение градиента на итерации.

В виду сложности вычисления обратной матрицы, вместо вычисления B_k^{-1} проводят обновление обратной к B_k матрицы $H_k = B_k^{-1}$:

$$H_{k+1} = (I - p_k s_k y_k^T) H_k (I - p_k y_k s_k^T) + p_k s_k s_k^T,$$

где $p_k = \frac{1}{y_k^T s_k}$.

2. Применение нейронных сетей в задачах прогнозирования

2.1. Этапы нейросетевого предсказания финансовых временных рядов

В последнее время одной из самых популярных задач, при решении которой используют нейронные сети, является задача прогнозирования.

Прогнозирование базируется на предсказании будущих событий. Например, мы имеем заданное n -ное количество определенных значений $\{y(t_1), y(t_2), \dots, y(t_n)\}$, которые меняются с течением времени t_1, t_2, \dots, t_n . Задачей прогнозирования в этом случае будет предсказывания значения $y(t_{n+1})$ в будущий момент времени t_{n+1} .

Основная цель процесса прогнозирования – уменьшить риск при принятии решений. В большинстве случаев прогноз может оказаться неточным, его ошибка зависит от системы, которую использовали при прогнозировании. Типичными примерами прогнозов являются: прогнозы цен на фондовой бирже, прогноз погоды, прогноз потребления электроэнергии, прогноз отказов технических систем и пр.

Нейронная сеть может быть применена при решении задачи прогнозирования временных рядов, что будет показано в этой работе. Процесс состоит из следующих этапов:

- выбор пользователем произвольного временного ряда с N количеством отсчетов;
- разбивка данного ряда на три множества: обучающую, тестирующую и контрольную выборки;
- подача выборок на вход сети.

В результате получаем значение временного ряда в требуемый момент времени.

Проведение предварительной (препроцессорной) обработки информации позволяет повысить качество прогноза, поэтому данная процедура является необходимой. Чаще всего это масштабирование значений отсчетов для приведения их в единый диапазон.

По сути, выборка является дискретной функцией, которая задана точками в интервале $[0, N]$ и шагом 1.

Предшествующее поведение нейронной сети позволяет предсказать ее будущую реакцию при прогнозировании, в этом и есть ее основная роль. То есть при наличии информации о значениях переменной x в моменты, которые предшествовали данному прогнозированию $x(k-1), x(k-2), \dots, x(k-N)$, сеть способна найти наиболее вероятное значение последовательности $\bar{x}(k)$ в текущий момент времени k . Фактическая погрешность прогнозирования $\varepsilon = x(k) - \bar{x}(k)$ и значения этой погрешности в предшествующие моменты времени используются для адаптации весовых коэффициентов сети [8].

Выбор архитектуры сети основан на апробации нескольких конфигураций, имеющих различное количество элементов. Для решения задачи прогнозирования могут быть использованы следующие типы нейронных сетей:

- многослойный персептрон (MLP);
- радиально-базисная сеть (RBF);
- обобщенно-регрессионная сеть (GRNN);
- сеть Вольтерри;
- сеть Эльмана.

На рисунке 6 представлена схема предсказания временных рядов при помощи нейронной сети [4].

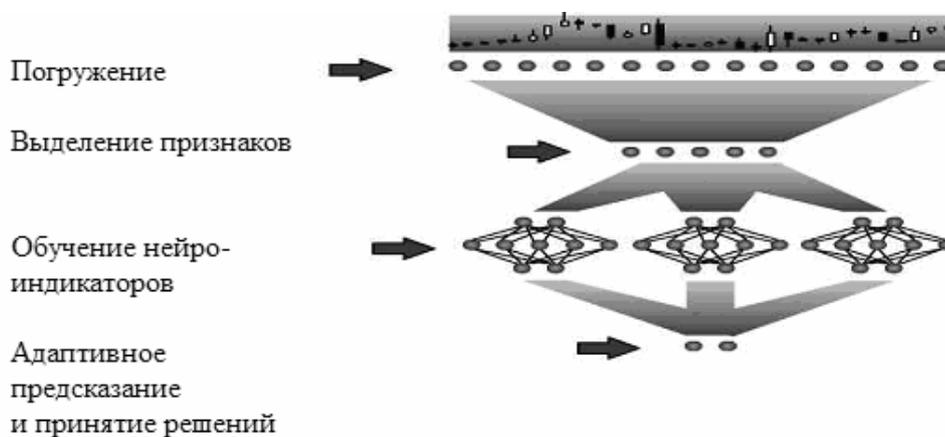


Рисунок 6 – Схема нейросетевого предсказания финансовых временных рядов

На первом этапе нейросетевого предсказания временных рядов происходит определение временного ряда и формирование базы данных. На втором этапе необходимо проведение кодирования входов-выходов, так как нейронные сети работают с числами. Следующим этапом является нормирование данных, это необходимо для исключения зависимости результата от единиц измерения. На четвертом этапе проводят предобработку данных, удаляют очевидные регулярности для того, чтобы облегчить выявление нетривиальных закономерностей. Пятый этап направлен на обучение нескольких нейронных сетей, которые имеют различную архитектуру. На данном этапе влияние на результат оказывают размер сети и ее начальная конфигурация. На шестом этапе отбираются сети с наименьшей ошибкой предсказания. На седьмом этапе проводят адаптивное предсказание и принимается решение.

2.2. «Метод окон»

Применение общих принципов нейромоделирования возможно в полном объеме при прогнозировании. Но наличие собственной специфичности финансовых временных рядов вносит свои коррективы. Так, например, при определении базовых характеристик данных на первом этапе необходимо учитывать торговую стратегию. Здесь может быть использован «метод окон» для получения входных образов при формировании входного множества. В методе окон определяются два окна W_i и W_0 , имеющие фиксированные размеры n и m соответственно. Эти окна обладают способностью к перемещению по временной последовательности с некоторым шагом и дают доступ к данным временного ряда. За передачу данных на вход нейронной сети отвечает первое окно W_i , а за передачу данных на выход сети второе W_0 . В качестве элемента обучающей выборки выступает пара $W_i > W_0$, которая возникает на каждом шаге. Смещение окна в правую сторону на один шаг приводит к получению следующего вектора. Строится предположение, что временная последовательность имеет скрытые зависимости. Проходя обучение и путем настраивания коэффициентов,

нейронная сеть стремится к извлечению этих закономерностей и формированию требуемой функции прогноза. Метод окон позволяет провести одношаговый и многошаговый прогноз [4].

Многошаговое прогнозирование – прогнозирование данного вида является долгосрочным и используется для определения основного тренда и главных точек его изменения в будущем для определенного промежутка времени. Принцип работы прогнозирующей системы состоит в том, что полученные в ходе прогноза выходные данные для моментов времени $k+1$, $k+2$ и т.д. являются входными данными для прогнозирования на моменты времени $k+2$, $k+3$ и т.д, соответственно.

Одношаговое прогнозирование является краткосрочным и используется для определения абсолютных значений последовательности. Следовательно, прогнозирующая система реализует прогноз только на один шаг вперед. При этом для проведения прогноза на следующем шаге используется реальное значение последовательности, а не спрогнозированное на предыдущем, как в многошаговом прогнозировании.

Отметим, что прогнозировать можно как качественные, так и численные значения.

3. Практическая часть научно-технического исследования

3.1. Прогнозирование цен закрытия акций Сбербанка с использованием нейронных сетей в программе STATISTICA

За последние годы популярность нейронных сетей (НС) сильно возросла. Наибольшую эффективность нейронные сети проявляют, решая задачи прогнозирования, классификации или управления. Это обуславливается несколькими аспектами:

- Во-первых, нейронные сети обладают широким рядом возможностей. Это обусловлено их нелинейной природой, и позволяет говорить о потенциале нейронных сетей в моделировании. В отличие от традиционного в большинстве областей линейного моделирования, которое имеет развитые инструменты оптимизации, нейронные сети за счет своего главного преимущества – возможности выстраивать сложные зависимости – являются более эффективными при решении задач моделирования, где линейная аппроксимация неудовлетворительна. Кроме того, НС позволяют моделировать линейные зависимости при работе с большим числом переменных, что позволяет снять ограничение размерности, присущее традиционным методам моделирования.

- Во-вторых, нейронные сети достаточно просты в использовании. Перед тем как начать работу с сетью, она должна пройти этап обучения на примерах. При этом структуру данных алгоритмы обучения определяют автоматически. Единственная сложность, она же и ее большое преимущество, в работе с нейронными сетями – это настройка ее параметров. На начальных этапах важно подготовить представительные данных для обучения. Они должны максимально описывать взаимосвязи, которые могут проявиться в процессе их моделирования. Для этого от пользователя требуется глубокое понимание предметной области. Также, основываясь на своих знаниях, пользователь должен выбрать наиболее удачную из предложенных архитектуру сети и интерпретировать полученные в ходе моделирования результаты. Но стоит отметить, что уровень знаний, которым необходимо

обладать для эффективного использования НС, ниже, чем при использовании традиционных методов статистики.

Дальнейшее развитие НС, основанных на интуитивно понятной биологической модели нервных связей, направлено на создание искусственного интеллекта, что может привести человечество к новой эпохе мыслящих компьютеров.

В прикладной статистике уже сейчас нейронные сети, которые реализованы в системе ST Neural Networks, являются мощным математическим инструментом, который позволяет получать результаты высокой точности при решении задач прогнозирования.

На данные момент модно выделить два основных класса задач прогнозирования: классификация и регрессия.

Прогнозирование в задачах классификации предполагает, что входной набор данных будет распределен по строго определенным классам. При этом на выходе нейронной сети всегда будет только одно значение, определенный класс переменной. Примером таких прикладных задач может послужить обнаружение спама среди корреспонденции, медицинская диагностика с определением вида заболевания, предсказание месторождений полезных ископаемых и др.

В свою очередь, регрессия нацелена на прогнозирование значения переменной, чаще всего принимающей непрерывные числовые значения. При этом на выходе нейронной сети требуется только одна числовая переменная. Примерами задач регрессии являются определение цены акций на завтрашний день, расчет прибыли на следующий год, определение возраста пользователя по его действия в сети Интернет и т.п.

Практическая часть данного исследования поделена на две части:

1. Прогнозирование реальных значений цен закрытия акций. В данном случае оценивать сеть мы будем по ошибке прогноза: чем меньше ошибка прогноза, тем лучше прогнозирует сеть.

2. Прогнозирование направления движения цены. В данном случае нужно убедиться, что способ принятия решения отличается от подбрасывания монетки. Нейронная сеть должна распознать комбинацию значений индикатора и на их основе оценить шансы повышения или понижения цены.

В обоих случаях мы будем строить одношаговый прогноз – прогноз на один день вперед. Для выполнения прикладной части диссертационной работы был использован программный пакет STATISTICA.

3.2. Выбор программного продукта для прогнозирования финансовых временных рядов с использованием нейронных сетей

STATISTICA – это программный пакет, обладающий современным и мощным инструментарием, позволяющим осуществлять быстрый анализа данных и поиск статистических закономерностей. Данное программное обеспечение позволяет использовать нейронные сети для решения различного рода задач. Функциональный набор для работы с сетями реализован в модуле STATISTICA Neural Networks (ST Neural Networks).

Использование программы ST Neural Networks в сравнении с другими программными продуктами, предоставляющими возможности прогнозирования на основе нейронных сетей, имеет ряд преимуществ, которые заключаются в следующем:

1. В программе встроено преобразование данных: пре- и пост-процессирование, имеется возможность выбрать данные, закодировать номинальные значения, а также имеется шкалирование, нормализация, удаление пропущенных данных с интерпретацией для классификации.

2. Программный пакет предоставляет уникальный инструмент автоматического нейросетевого поиска «Автоматизированная нейронная сеть» (АНС), которая не имеет аналогов. С помощью него пользователь имеет возможность последовательно пройти все этапы создания различного рода нейронных сетей.

3. Пакет поддерживает архитектуры нейронных сетей практически неограниченного размера.

4. Реализованы наиболее популярные сетевые архитектуры, включая Многослойные персептроны, Радиальные базисные функции и самоорганизующиеся карты Кохонена.

5. В ST Neural Networks представлены самые современные, оптимизированные и мощные алгоритмы обучения сети (включая методы сопряженных градиентов, алгоритм Левенберга-Марквардта, BFGS, алгоритм Кохонена).

6. Данный программный пакет позволяет запись полноценных макросов для любых анализов; создание собственных нейросетевых анализов и приложений с помощью STATISTICA Visual Basic.

7. ST Neural Networks также предоставляет новую опциональную возможность генерации исходного кода нейронной сети на языках распространенных языках программирования C, C++, C#, Java, PMML (Predictive Model Markup Language), для интеграции сети во внешнюю среду.

3.3. Исследуемые выборки

Объект исследования – нейросетевые модели, которые используются при прогнозировании финансовых временных рядов, в нашем случае мы использовали в качестве такого ряда – цены закрытия акций компании «Сбербанк». Сбербанк является одной из крупнейших кредитных организаций по размеру активов РФ. Также данная компания является одним из системообразующих банков российской банковской системы.

Сбербанк занимает более 30% банковской системы РФ и выступает главным аккумулятором средств клиентов. В секторе кредитования на долю банка приходится свыше 40% от общего выданных займов, а клиентская база насчитывает более миллиона предприятий.

Банк активно реализует инновационные программы в финансовой сфере и выступает одним из наиболее передовых представителей отрасли. В структуре группы Сбербанка присутствует множество лабораторий, специализирующихся на развитии технологической базы организации. Кроме того, компания присутствует в таких сегментах бизнеса как торговля

недвижимостью, медицинские услуги, электронная коммерция.

В одной из задач к научно-исследовательской работе нужно проанализировать, зависит ли точность прогноза от объема выборки, на которой обучается нейронная сеть. В данном исследовании были использованы две выборки различного объема (рис. 7 – 8):

1. Цены закрытия акций Сбербанка за 2019 год (247 значений)



Рисунок 7 – График цен закрытия акций Сбербанка за 2019 г (247 значений)

2. Цены закрытия акций Сбербанка за 4 года: 2016-2019 г. (1011 значений)

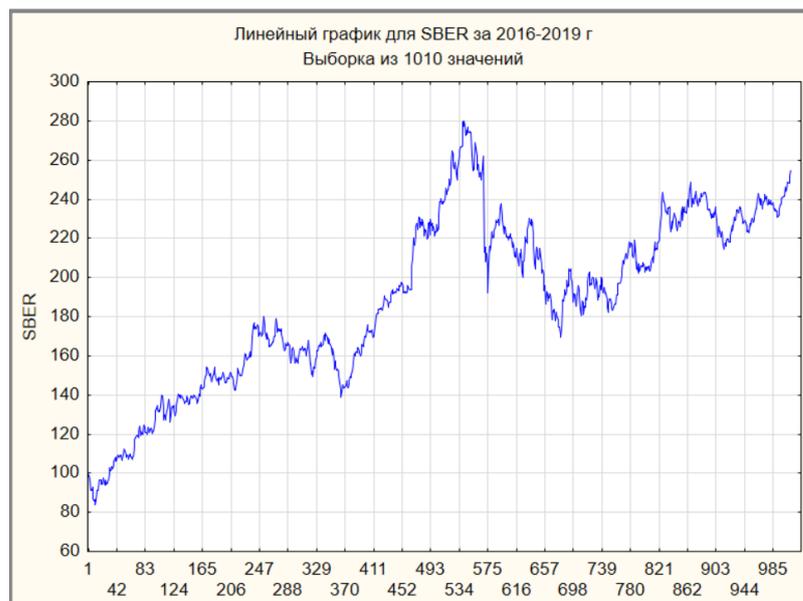


Рисунок 8 – График цен закрытия акций Сбербанка за 2016-2019 г (1010 значений)

Как мы можем заметить, во второй выборке присутствует аномальное падение цены закрытия акции: падение почти на 44 единицы, что составляет 17%:

Дата	Значение
06.04.2018	256,76
09.04.2018	213

По данным РБК, в апреле 2018 года после введения новых санкций США стоимость акций Сбербанка на Мосбирже упала более чем на 20%.

Источником данных является информационный портал Finam.ru. Российский фондовый рынок стремительно развивается, и для эффективного вложения средств инвесторам нужна оперативная информация о том, где купить акции, по какой стоимости, как котировки ценных бумаг меняются в течение торговой сессии, что такое государственные ценные бумаги, корпоративные ценные бумаги и др. На страницах портала можно получить исчерпывающую информацию, рекомендации и прогнозы аналитиков, воспользоваться инструментарием для технического анализа и многое другое.

3.4. Предобработка данных для прогнозирования финансовых временных рядов с использованием нейронных сетей

Для построения прогноза нейросетевыми моделями данные должны пройти предобработку. Любая нейронная сеть на входе принимает числовые значения и за тем на выходе выдаёт также числовые значения. Обычно для каждого элемента сети передаточная функция выбирается таким образом, чтобы аргумент, который считается входным мог принимать любые значения, а значения, которые выходят лежали бы в строго ограниченном диапазоне ("сплющивание"). Но при этом, хотя значения, которые входят могут быть произвольными, получается эффект насыщения. В этом случае элемент оказывается восприимчив только к входным значениям, лежащим в некоторой ограниченной области. Так как значения, которые считаются выходными, всегда принадлежат к четко определенной ограниченной области, а вся информация должна быть представлена в числовом виде, то для решения

методами нейронных сетей реальных задач требуется пройти следующие этапы:

- этап предварительной обработки, или препроцессирования,
- этап заключительной обработки, или постпроцессирования данных.

В пакете ST Neural Networks имеются все необходимые средства и инструменты.

Все числовые значения должны быть преобразованы в определённый диапазон, подходящий для сети. Зачастую, такие данные масштабируются с использованием линейной шкалы. Для преобразования в нужный диапазон числовых значений в пакете ST Neural Networks реализованы алгоритмы минимакса и среднего/стандартного отклонения, которые находят масштабирующие параметры автоматически [10].

Из вышесказанного следует, что для задач регрессии в качестве входных данных можно использовать реальные значения цен закрытия котировок, программный пакет STATISTICA автоматически масштабирует данные в нужный диапазон.

Что же касается прогнозирования направления движения цены (классификация), то в качестве входов и выходов НС был выбран логарифм относительного приращения цен закрытия, который равен:

$$\log\left(\frac{C_t}{C_{t-1}}\right) \approx \frac{\Delta C_t}{C_{t-1}},$$

где C_t – значения цен закрытия, котировок, а ΔC_t – изменения котировок.

Логарифм относительного приращения для длительных временных рядов (в нашем случае, это выборка из 1010 значений) был использован для того, чтобы учесть влияние инфляции на формирование цены.

3.5. Выбор типа нейронной сети

В регрессионных задачах основной целью является оценка значения числовой выходной переменной, принимающей непрерывный диапазон

значений, по значениям переменных, которые считаются входными. Для решения задач прогнозирования пакет ST Neural Networks предлагает следующие типы нейронных сетей: многослойный персептрон (MLP), радиальная базисная функция (RBF), а также линейная сеть. В рамках решаемых задач наиболее подходящей была признана модель многослойного персептрона, т.к. линейная сеть хоть и имеет простую архитектуру, однако не дает лучших результатов, в то время как сети RBF в сравнении с MLP имеют ряд существенных недостатков:

1. Сети RBF более чувствительны к «проклятию размерности» и испытывают значительные трудности, когда число входов велико.

Появление новой размерности в пространстве данных при каждом дополнительном входном элементе сети называют «проклятием размерности». И так из этой особенности вытекает: нужно иметь довольно много точек для того, чтобы N-мерное пространство достаточно плотно "заселить" и при этом "увидеть" структуру данных. С ростом размерности пространства, нужное число точек возрастает по экспоненте. Большое количество типов НС, как и многослойный персептрон MLP, от проклятия размерности страдают меньше, чем другие методы прогнозирования. Это обусловлено тем, что за проекциями участков многомерного пространства в пространстве малой размерности умеют следить только НС. Однако, проклятие размерности до сих пор остается весьма серьезной проблемой. Лишь качественно подготовив данные, исключив избыточные входные переменные, можно значительно улучшить качество работы сети [10].

2. На практике было выяснено: для того, чтобы правильно смоделировать типичную функцию, сеть MLP требует гораздо меньшее количество скрытых нейронов по сравнению с сетью RBF.

Многослойный персептрон в настоящее время является самой популярной и часто используемой моделью. Каждый элемент такой сети строит взвешенную сумму своих входов, после чего через передаточную функцию пропускает данную величину активации. Так получается выходное

значение этого элемента. При это все элементы организованы в послойную топологию с прямой передачей сигнала. Данную сеть идентифицировать как модель вход-выход, где веса, а также пороговые значения (смещения) являются свободными параметрами модели. Такая сеть способна смоделировать функцию практически любой степени сложности, при этом количество элементов в каждом из слоев, собственно, определяет сложность функции. Одним из ключевых вопросов при построении MLP является определение количества промежуточных слоев и элементов в них [10]. Слои в MLP используются для того, чтобы «разгрузить» сеть от лишних нейронов.

Чтобы нейронная сеть демонстрировала хорошие результаты прогнозирования, важно правильно ее обучить. Обучение сети проходит по следующей схеме (рис.9):



Рисунок 9 – Схема процесса обучения нейронной сети

Весовые коэффициенты сети должны изменяться, пока ошибка обучения сети не станет минимальной. Стоит отметить, что сто процентной точности нельзя достичь, так как в той или иной мере будут присутствовать погрешности.

В программном пакете STATISTICA существует три способа обучения сети:

- Самый часто используемый алгоритм обучения – метод градиентного спуска;
- Метод сопряженных градиентов;
- BFGS метод.

В данной работе нейронные сети обучались методом BFGS, который является самым быстрым из реализованных в пакете ST Neural Networks, что позволяет нам обучать большее количество сетей за меньшее количество времени. Также данный метод имеет наименьшую ошибку на контрольной и обучающей выборке по сравнению с другими алгоритмами обучения.

В данной исследовательской работе при помощи многослойного перцептрона было построено большое количество нейронных сетей с разной архитектурой. При проведении экспериментов мы меняли количество нейронов, подаваемых на вход и количество нейронов в скрытом слое для того, чтобы выбрать наилучшую сеть с наименьшей ошибкой прогноза. При каждом новом эксперименте для скрытого слоя MLP мы использовали либо логистическую функцию активации, либо гиперболическую, так как данные функции наиболее часто используются для построения прогнозов.

Подробнее о функциях активации:

Логистическая функция форму S-образной кривой (сигмоида), при этом выходные значения лежат в интервале (0, 1):

$$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$$

где x – линейная комбинация входных сигналов.

Гиперболическая функция (функция гиперболического тангенса) имеет график сигмоидной кривой (как и у логистической функции), только здесь выходные значения лежат в интервале (-1, +1). По сравнению с логистической данная функция часто дает лучшие результаты, благодаря своему свойству симметрии.

Экспериментальным путем было доказано, что лучшие результаты при прогнозировании финансовых временных рядов дают сети с гиперболической функцией активации:

$$f(x) = \text{th}(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})}$$

Активационная функция преобразовывает средневзвешенную сумму

ВХОДНЫХ ВОЗДЕЙСТВИЙ В ВЫХОДНОЙ СИГНАЛ:

$$P = \sum_{i=1}^n x_i \omega_i - T$$

где T – порог нейрона.

3.6. Прогнозирование котировок Сбербанка с помощью авторегрессионных моделей

На первом этапе исследования мы построили авторегрессионную модель для того, чтобы сравнить полученный прогноз на основе нейросетей с прогнозом, полученным на основе модели AR:

Авторегрессионная модель – это модель временных рядов, значения временного ряда которой в данный момент линейно зависят от предыдущих значений:

$$X_t = c + \sum_{i=1}^p a_i X_{t-i} + \varepsilon_t,$$

где a_1, \dots, a_p – параметры модели (коэффициенты авторегрессии), c — постоянная (часто для упрощения предполагается равной нулю), ε — белый шум.

Авторегрессионные модели были построены с использованием программы Wolfram Mathematica (Приложение А).

Наилучшие результаты получаются для $AR=1$ при больших M :

$$X_t = c + rX_{t-1} + \varepsilon_t$$

Следует выбрать оптимальное количество точек, так как при больших M , количество прогнозных точек уменьшается, а, следовательно, сравнение с прогнозируемой моделью, которая будет построена нейронными сетями, может получиться не совсем корректное.

В нашем случае, было построено две модели AR (1) для малой выборки (247 значений (рис. 10–11)) и для большой выборки (1010 значений). Прогнозируемые и реальные значения цен закрытия акций Сбербанка для малой выборки представлены на рисунке 10.

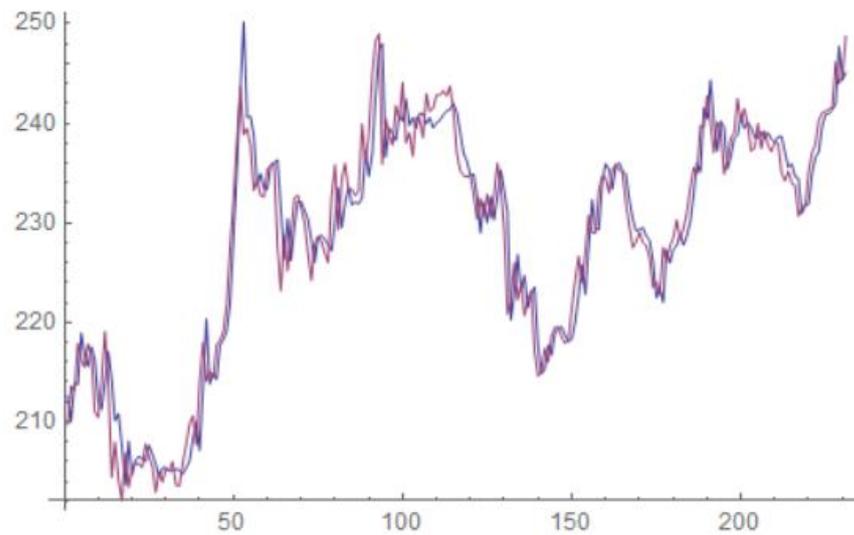
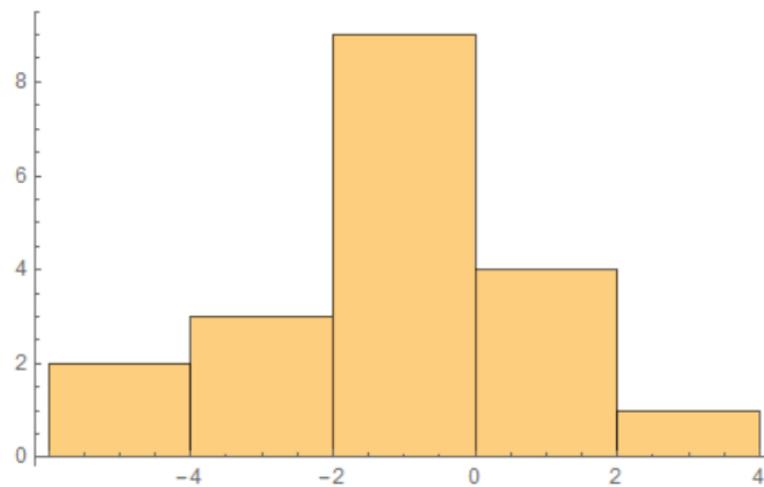


Рисунок 10 – Прогнозируемые и реальные значения цен закрытия акций Сбербанка для малой выборки

`Histogram[Z - Z1]`
`DistributionFitTest[Z - Z1]`



0.0445394

Рисунок 11 – Гистограмма и результат теста распределения данных для малой выборки

Статистические параметры моделей представлены в таблице 1.

Таблица 1. Статистические параметры моделей AR(1) для разных выборок

	Количество точек, для которых была построена модель AR(1)	Стандартное отклонение	Результат теста: имеют ли исходные данные нормальное распределение	Средняя относительная ошибка в % (MAPE)
AR (1) для 247 значений	227	1,977	0,044	0,683
AR (1) для 1010 значений	990	1,799	0,021	0,690

Количество точек M для построения моделей AR(1) выбрано таким образом, чтобы для последних 20 точек (тестовая выборка SBER) можно было построить прогнозы и вычислить ошибку прогноза (рис. 12-13).

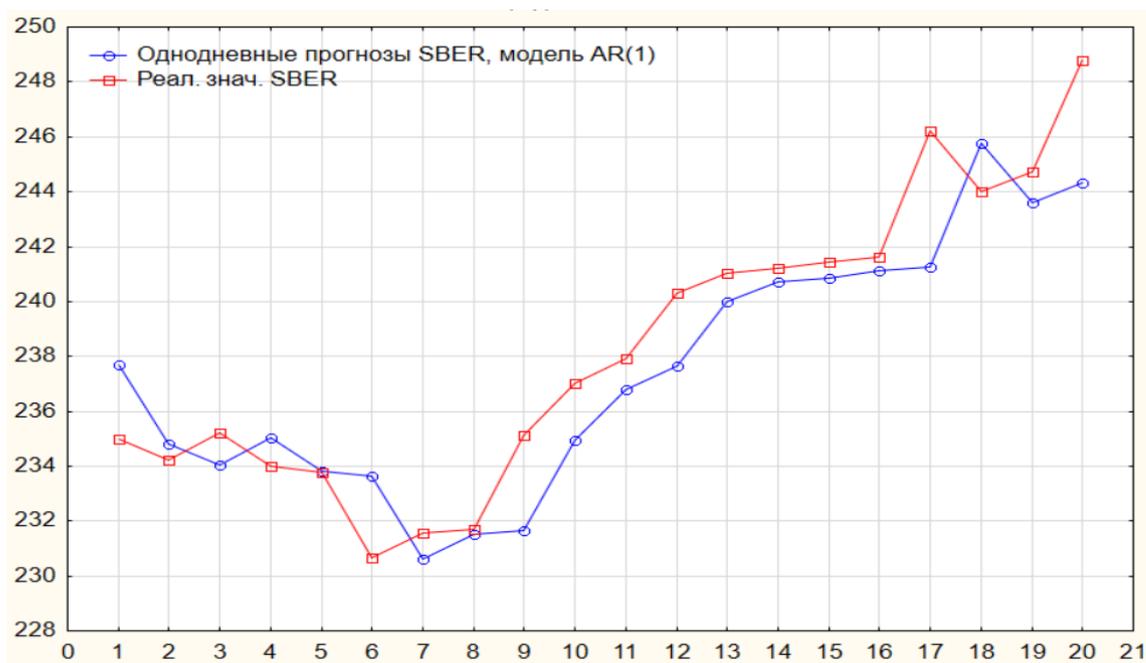


Рисунок 12 – Однодневные прогнозы для тестовой выборки SBER и соответствующие реальные значения, модель AR(1)

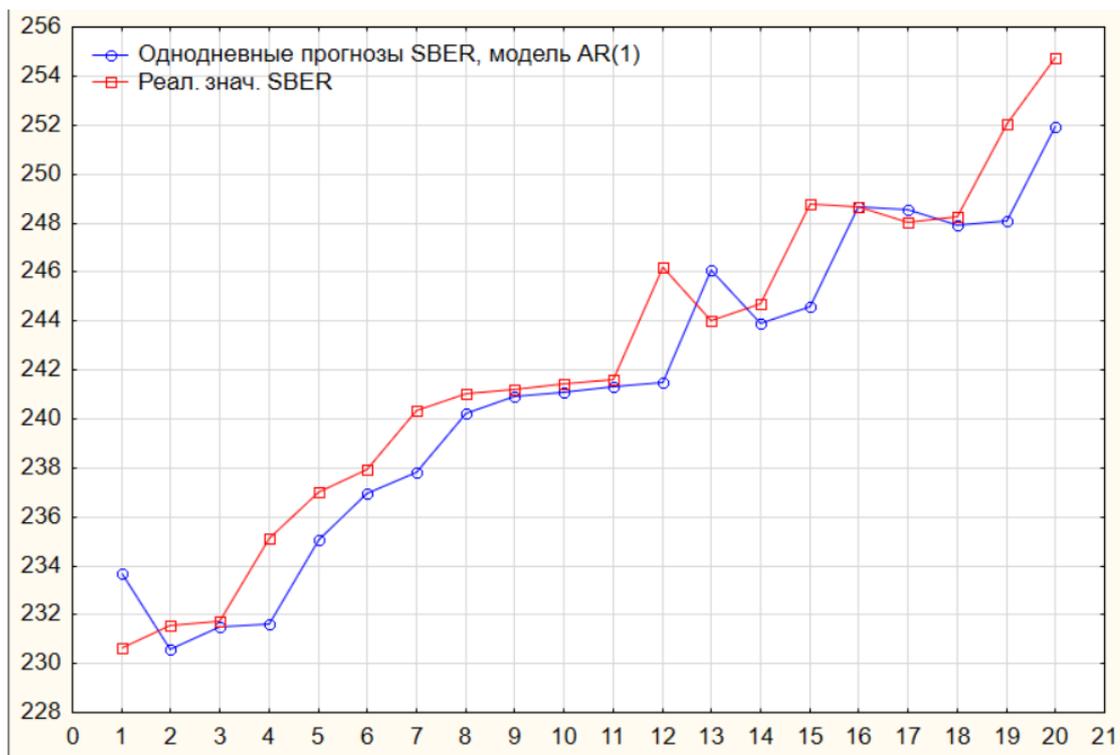


Рисунок 13 – Однодневные прогнозы для тестовой выборки SBER и соответствующие реальные значения, модель AR(1)

3.7. Прогнозирование котировок Сбербанка с использованием нейронных сетей (Регрессия)

Как было сказано выше, для построения прогноза с использованием нейронных сетей было использовано две выборки: малая (227 значения) и большая (1010 значений) в целях сравнения точности прогнозирования: при увеличении объёма выборки для обучения сети увеличится ли точность построенных прогнозов или эти данные избыточны? Для оценки точности прогноза оставим последние 20 значений для тестовой выборки (как в малой, так и в большой).

Малая выборка. В построении нейронных сетей участвуют 227 значений цен закрытия акций Сбербанка, из которых 80 % значений используется для обучающей выборки, остальные 20 % составляют контрольную выборку. Контрольная выборка используется для остановки процесса обучения нейронной сети. Когда ошибка на контрольной выборке начинает возрастать, это служит признаком того, что модель уже переобучается, следовательно, на этом моменте стоит прекращать обучение.

Статистические параметры малой выборки (247 значений) представлены в таблице 2.

Таблица 2. Статистические параметры малой выборки SBER

	Статистические параметры малой выборки SBER
Стандартное отклонение	13,31
Среднее значение	226,72
Минимум	186,99
Максимум	249

Эксперимент 1.

На вход подаем выборку из 20 значений. Из 2000 обученных сетей программа предложила нам 10 наилучших для сохранения и последующего анализа. Наилучшими она признала их ввиду того, что они имели наименьшую ошибку на обучающей и контрольной выборке. Ошибка на обучающей выборке у всех выбранных нейронных сетей была примерно одинаковая – 3,5, что составляет 1,7 %. Отобранные программой сети сравнивались между собой путём вычисления ошибки прогноза на тестовой выборке. Для оценки прогноза использовалась средняя относительная ошибка в процентах (MAPE):

$$MAPE = \frac{1}{N} \sum_{t=1}^N \frac{|Z(t) - \hat{Z}(t)|}{Z(t)} \cdot 100\%,$$

где $Z(t)$ – реальное значение цены акции;

$\hat{Z}(t)$ – соответствующее прогнозируемое значение.

По результатам данного сравнения наилучшей признана сеть следующей архитектуры: многослойный персептрон MLP 20-4-1 с логистической функцией активации для скрытых нейронов. Данная сеть содержит 4 нейрона в скрытом слое, 20 входов и один выход. Ошибка прогноза построенной сети на тестовой выборке составляет 0,687%.

Проверим адекватность построенной модели MLP 20-4-1 (рис. 14-16):

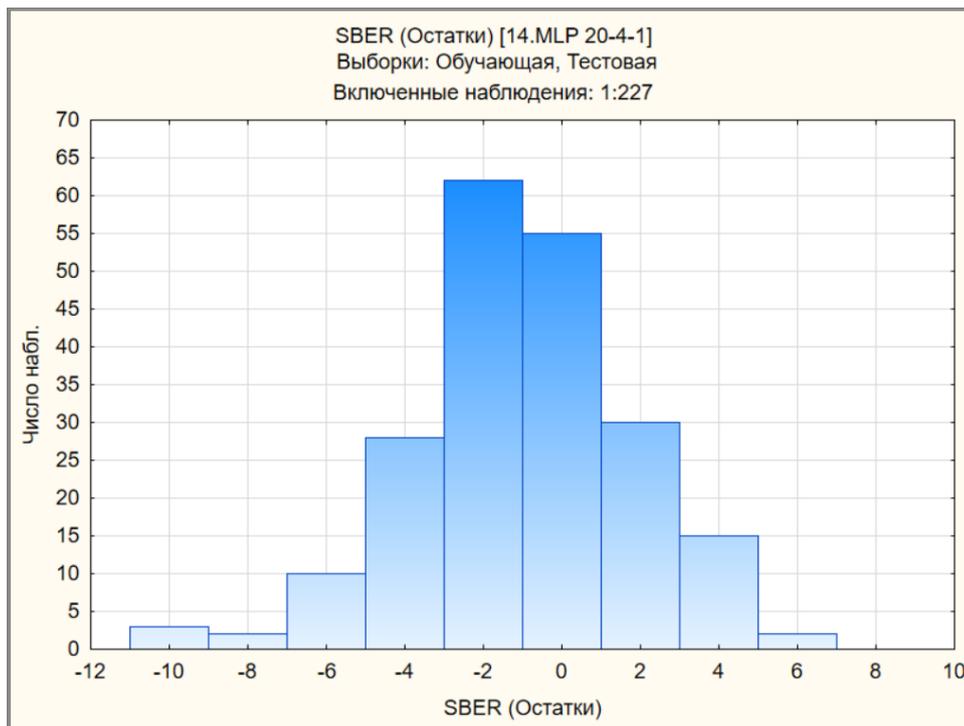


Рисунок 14 – Распределение остатков на обучающей и контрольной выборке, MLP 20-4-1

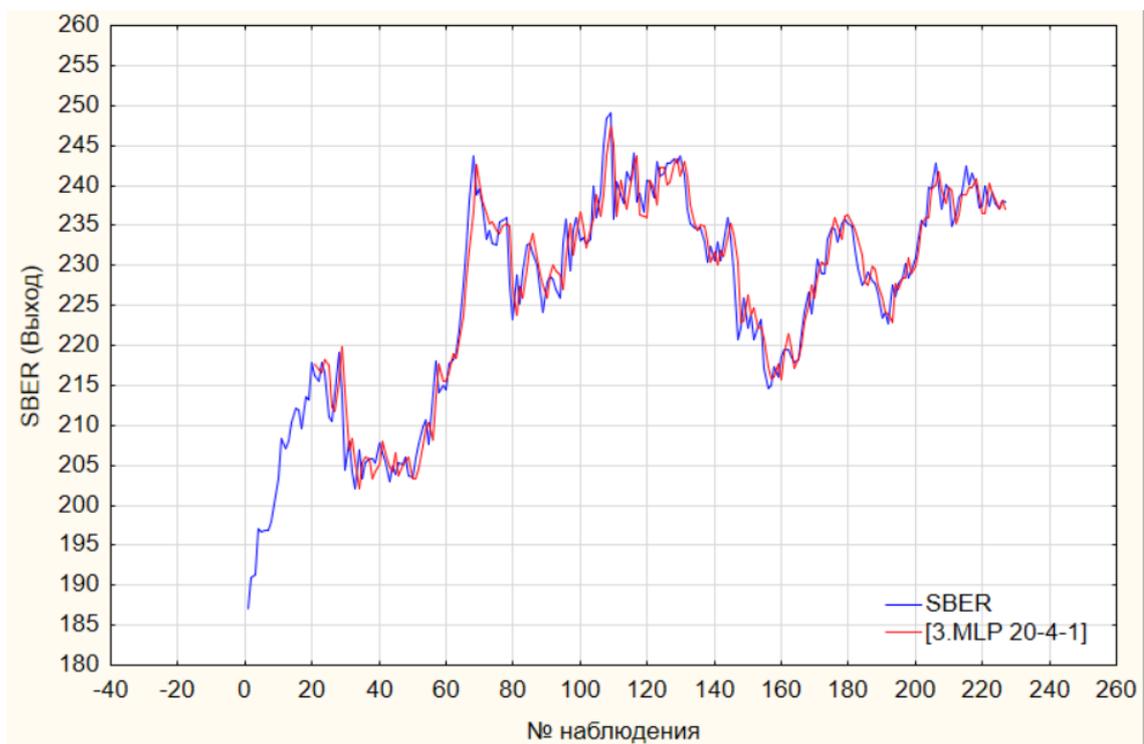


Рисунок 15 – Описание реальных данных сетью MLP 20-4-1

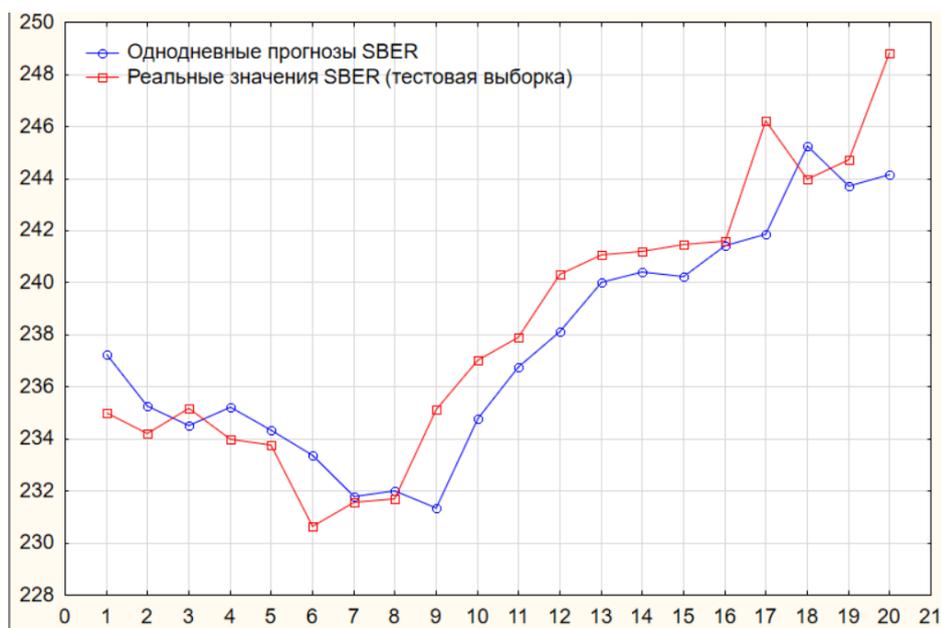


Рисунок 16 – Однодневные прогнозы SBER для тестовой выборки и соответствующие реальные значения, MLP 20-4-1

Достоинством данной сети является то, что она хорошо прогнозирует цены закрытия акции компании «Газпром» (GAZP). Коэффициент корреляции между данными выборками 0,728, что свидетельствует о высокой степени связи между переменными: если цены акций SBER будут расти в цене, то и акции GAZP тоже будут расти. Следовательно, цены закрытия акций GAZP можно использовать для построения прогноза сетью, которая обучалась на акциях SBER.

Статистические параметры малой выборки GAZP (цены закрытия акций за 2019 год, 252 значения) представлены в табл.3.

Таблица 3. Статистические параметры малой выборки GAZP

	Статистические параметры малой выборки GAZP
Стандартное отклонение	38,94
Среднее значение	208,33
Минимум	149,49
Максимум	270,74

На вход сети подавались все имеющиеся значения акций GAZP для построения однодневных прогнозов. Однодневные прогнозы GAZP и соответствующие реальные значения представлены на рисунке 17. Ошибка

прогноза MAPE составила 1,77%.

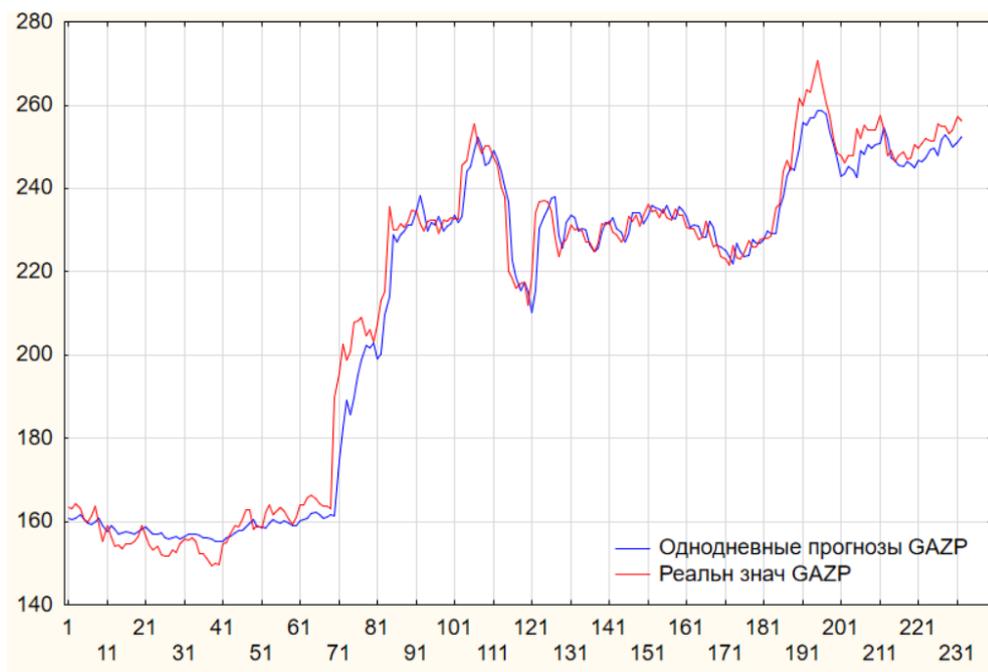


Рисунок 17 – Однодневные прогнозы GAZP и соответствующие реальные значения, MLP 20-4-1

Эксперимент 2.

На вход подаем выборку из 6 значений. Из 2000 обученных сетей программа предложила нам 10 наилучших для сохранения, которые имеют наименьшую ошибку на обучающей и контрольной выборке. Ошибка на обучающей выборке варьируется от 3,9 до 4,5, что составляет примерно 2–2,5%. Аналогично эксперименту 1 – выбранные сети сравнивались между собой путём вычисления ошибки прогноза MAPE на тестовой выборке SBER.

По результатам данного сравнения лучшей признана сеть с архитектурой многослойного персептрона MLP 6-3-1 с гиперболической функцией активации для скрытых нейронов. Данная сеть содержит 3 нейрона в скрытом слое, 6 входов и 1 выход. Ошибка прогноза MLP 6-3-1 на тестовой выборке составляет 0,743%.

Проверим адекватность построенной модели MLP 6-3-1 (рис.18-20):

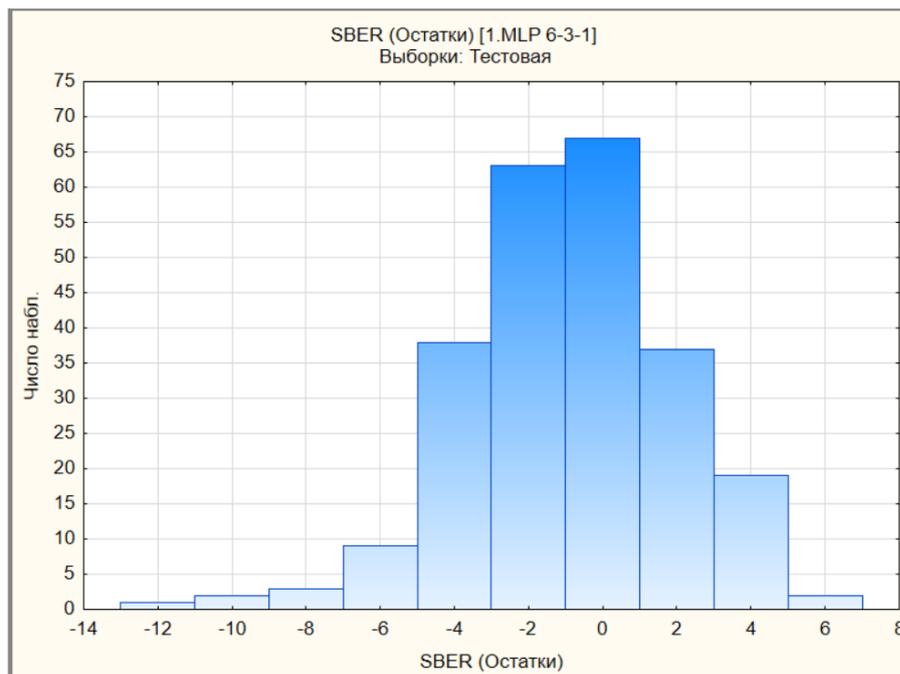


Рисунок 18 – Распределение остатков на обучающей и контрольной выборке, MLP 6-3-1

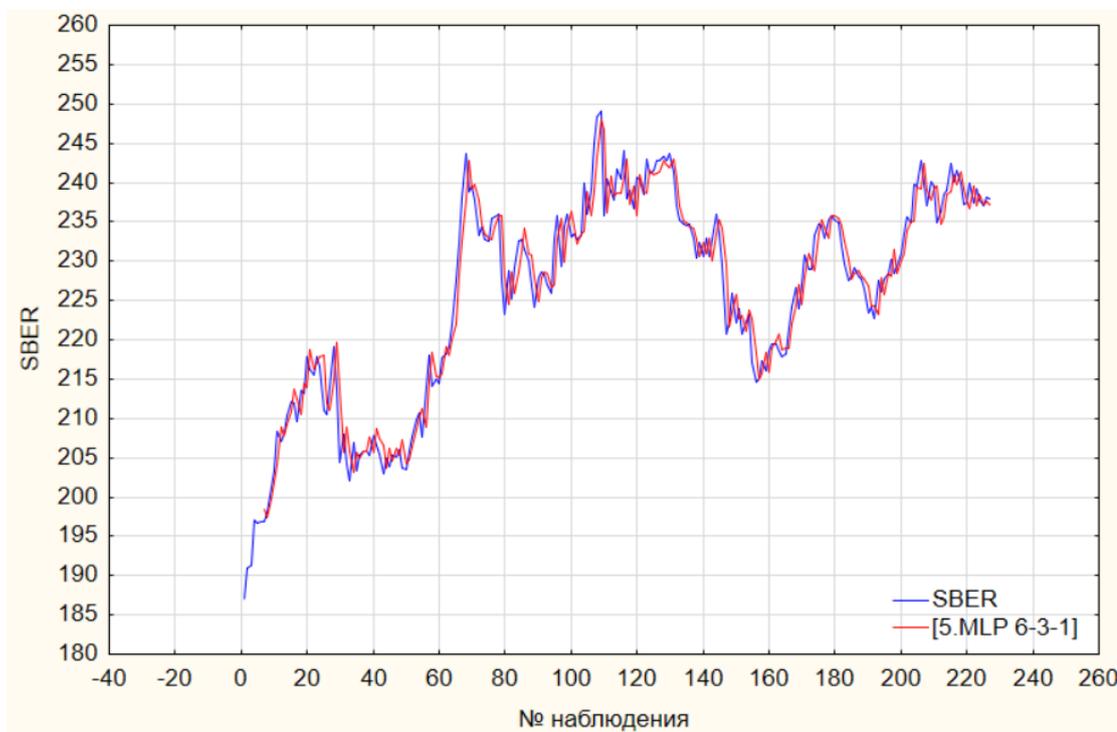


Рисунок 19 – Описание реальных данных сетью MLP 6-3-1

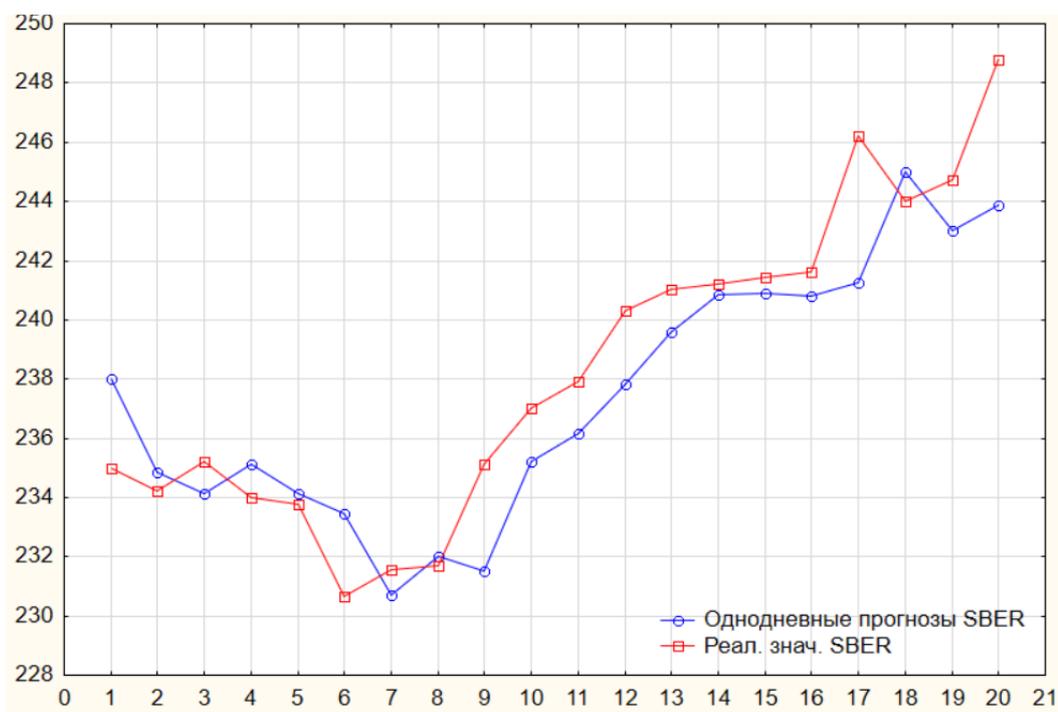


Рисунок 20 – Однодневные прогнозы для тестовой выборки SBER и соответствующие реальные значения, MLP 6-3-1

Проверим прогнозируемость модели на акциях GAZP. Однодневные прогнозы GAZP и соответствующие реальные значения представлены на рисунке 21. Ошибка прогноза MAPE составила 1,65%.

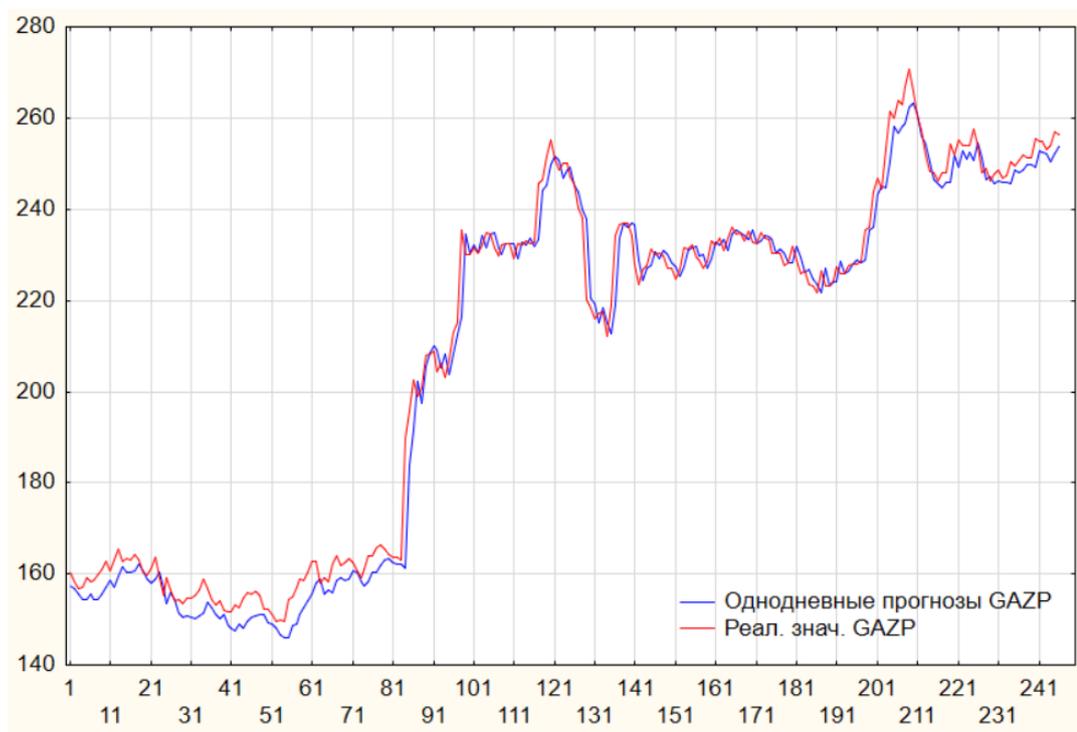


Рисунок 21 – Однодневные прогнозы GAZP и соответствующие реальные значения, MLP 6-3-1

Проводилось большое количество экспериментов: на вход подавалось различное количество нейронов: от 3 до 25, в скрытом слое количество нейронов варьировалось от 2 до 20. Для сетей одинаковой архитектуры задавались разные функции активации: либо логистическая, либо гиперболическая. В данном разделе представлены самые удачные эксперименты: сеть с архитектурой MLP 20-4-1 (логистическая функция активации) и MLP 6-3-1 (гиперболическая функция активации). Если обучать сеть другими алгоритмами (в нашем случае использовался алгоритм обучения BFGS), ошибка прогноза и ошибки на контрольных и обучающих выборках резко возрастают. Если же сети обучаются одним и тем же алгоритмом, то в большинстве случаев ошибка прогноза на тестовой выборке SBER колеблется около одного значения – 0,7%, при этом на точность прогноза не влияет ни количество нейронов в скрытом слое, ни количество нейронов, подаваемых на вход.

Большая выборка. По такому же принципу были построены сети различной архитектуры для выборки из 1010 значений. Результаты, полученные на данной выборке, полностью совпадают с результатами, представленными выше. Наше предположение, что с увеличением объёма обучающей выборки увеличится и точность прогноза, не оправдалось.

Достоинством построенных сетей является то, что они хорошо прогнозируют акции других компаний, с которыми у акций компании «Сбербанк» присутствует сильная положительная корреляция. Для всех сетей, которые были построены аналогично представленным выше, ошибка прогноза на прогнозных значениях компании GAZP варьируется от 1,65% до 5%, что говорит о хорошем качестве прогнозирования.

3.8. Прогнозирование котировок Сбербанка с использованием нейронных сетей (Классификация)

В задаче классификации сеть должна отнести каждое наблюдение к одному из нескольких классов (или, в более общем случае, оценить вероятность принадлежности наблюдения к каждому из классов). В пакете ST

Neural Networks для классификации используется номинальная выходная переменная – различные ее значения соответствуют различным классам.

В пакете ST Neural Networks классификацию можно осуществлять с помощью сетей следующих типов: многослойного персептрона, радиальной базисной функции, сети Кохонена и линейной сети. В нашем случае использовалась нейронная сеть типа MLP (многослойный персептрон) в связи с его преимуществом перед другими сетями, представленными в программе STATISTICA для решения задач классификации.

Удачный эксперимент.

Для обучения сети использовались две переменные: непрерывная входная – относительные приращения цен закрытия акций SBER и категориальная переменная: «Рост/Спад». Если по сравнению с предыдущим значением цена выросла – данное значение записываем в категорию «Рост», если произошло падение цены – «Спад».

На выходе мы должны получить нейросетевую модель, которая будет наилучшим образом угадывать направление цены.

Всего имеется 1009 значений относительных приращений SBER. В данной выборке присутствуют 6 значений, когда относительные приращения равны 0 – цена не менялась в течении двух дней, то есть нельзя однозначно отнести данные точки к категории роста или спада. С учетом данной информации, на обучение сети подавалось 982 значения (80 % – обучающая выборка, 20 % – контрольная). На вход подаем выборку из 20 значений.

Из 1000 обученных сетей программа предложила нам 6 наилучших для сохранения с наименьшей ошибкой на обучающей и на контрольной выборке (табл. 4).

Таблица 4. Итоги нейросетевых моделей на одном из экспериментов

Итоги моделей (Таблица.sta)								
N	Архитектура	Производительность обуч.	Контр. производительность.	Тест. производительность.	Алгоритм обучения	Функция ошибки	Ф-я актив. скрытых нейр.	Ф-я актив. выходных нейр.
2	MLP 20-7-2	68,56404	61,37566		BFGS 46	Сум. квадр.	Гиперболическая	Гиперболическая
3	MLP 20-8-2	58,08538	61,37566		BFGS 30	Энтропия	Гиперболическая	Софтмакс
4	MLP 20-6-2	56,79172	61,90476		BFGS 20	Энтропия	Логистическая	Софтмакс
6	MLP 20-6-2	54,98060	61,37566		BFGS 29	Энтропия	Гиперболическая	Софтмакс
7	MLP 20-7-2	60,54334	60,84656		BFGS 35	Сум. квадр.	Гиперболическая	Логистическая
8	MLP 20-8-2	75,67917	62,43386		BFGS 70	Энтропия	Логистическая	Софтмакс

Выбранные сети сравнивались между собой путём вычисления процента правильной классификации – насколько верно угадано направление цены акции. Для вычисления процента правильной классификации использовались 20 последних значений (тестовая выборка), которые не участвовали ни в обучающей, ни в контрольной выборке. Лучшей является сеть с архитектурой MLP 20-8-2 с логистической функцией активации для скрытых нейронов и функцией активации выходных нейронов – софтмакс.

Софтмакс — это обобщение логистической функции для многомерного случая.

Итоги классификации представлены в таблице 5.

Таблица 5. Итоги двухзначной классификации Рост/Спад.

		Рост/Спад (Итоги классификации) (Таблица. sta)		
		Выборки: Обучающая		
		Рост/Спад-0	Рост/Спад-1	Рост/Спад-Все
2. MLP 20-7-2	Все	371,0000	402,0000	773,0000
	Правильно	229,0000	301,0000	530,0000
	Неправильно	142,0000	101,0000	243,0000
	Правильно (%)	61,7251	74,8756	68,5640
	Неправильно (%)	38,2749	25,1244	31,4360
3. MLP 20-8-2	Все	371,0000	402,0000	773,0000
	Правильно	163,0000	286,0000	449,0000
	Неправильно	208,0000	116,0000	324,0000
	Правильно (%)	43,9353	71,1443	58,0854
	Неправильно (%)	56,0647	28,8557	41,9146
4. MLP 20-6-2	Все	371,0000	402,0000	773,0000
	Правильно	197,0000	242,0000	439,0000
	Неправильно	174,0000	160,0000	334,0000
	Правильно (%)	53,0997	60,1990	56,7917
	Неправильно (%)	46,9003	39,8010	43,2083
6. MLP 20-6-2	Все	371,0000	402,0000	773,0000
	Правильно	101,0000	324,0000	425,0000
	Неправильно	270,0000	78,0000	348,0000
	Правильно (%)	27,2237	80,5970	54,9806
	Неправильно (%)	72,7763	19,4030	45,0194
7. MLP 20-7-2	Все	371,0000	402,0000	773,0000
	Правильно	196,0000	272,0000	468,0000
	Неправильно	175,0000	130,0000	305,0000
	Правильно (%)	52,8302	67,6617	60,5433
	Неправильно (%)	47,1698	32,3383	39,4567
8. MLP 20-8-2	Все	371,0000	402,0000	773,0000
	Правильно	251,0000	334,0000	585,0000
	Неправильно	120,0000	68,0000	188,0000
	Правильно (%)	67,6550	83,0846	75,6792
	Неправильно (%)	32,3450	16,9154	24,3208

Используя построенные сети для классификации Роста/Спада цены акции на тестовой выборке, мы получили результаты, которые представлены в таблице 6.

Таблица 6. Процент правильной классификации выбранных нейронных сетей

Сети пронумерованы сверху вниз, как представлены в табл. выше	20-7-2	20-8-2	20-6-2	20-6-2	20-7-2	20-8-2
Процент правильной классификации на тестовой выборке (последние 20 значений)	0,55	0,65	0,65	0,7	0,55	0,6
Процент правильной классификации на обучающейся выборке (Таблица 5 «Итоги классификации»)	0,69	0,58	0,57	0,55	0,61	0,76

Мы можем сделать вывод, что выбранная сеть 20-8-2 хорошо классифицирует направление цены акции: процент правильной классификации на обучающей выборке составляет 76 процентов, а на тестовой выборке – 60 процентов. В этом случае, мы можем быть уверены, что данный способ принятия решения отличается от подбрасывания монетки.

Аналогичное исследование проводилось и на малой выборке (247 значений), процент правильной классификации построенных сетей составляет чуть больше 50%, что свидетельствует о том, что в данном случае объёма выборки, используемой при обучении, недостаточно для получения хорошо прогнозирующих нейросетевых моделей.

Неудачный эксперимент:

Используя классификацию Рост/Спад, мы получили положительные результаты при прогнозировании направления цены SBER при достаточном объёме исходных данных. Будут ли результаты такими же хорошими, если мы предложим следующую классификацию: цена увеличилась больше, чем на 1% – «Рост», произошел спад цены больше, чем на 1% – «Спад», и значение находится внутри этого диапазона, то относим данное значение к категории «Нейтрально».

У всех построенных сетей процент правильной классификации чуть больше 50%. Эксперимент проводился большое количество раз, при каждом новом обучении менялись параметры, способ обучения сети, функции

активации. На результаты данной классификации не следует опираться при принятии решения, так как, по сути, данный способ принятия решения не отличается от подбрасывания монетки.

3.9. Результаты проведенного исследования

Выводы данного исследования поделены на две части:

- ***Прогнозирование реальных значений цен закрытия акций (Регрессия):***

Результаты прогнозирования на малой выборке:

1. При проведении большого числа экспериментов были построены сети: MLP 20-4-1 (логистическая функция активации) и MLP 6-3-1 (гиперболическая функция активации), имеющие наименьшую ошибку прогноза. Нейронные сети обучались при помощи метода BFGS.

2. Достоинством построенных нейросетевых моделей является способность прогнозировать акции других компаний, с которыми у акций компании «Сбербанк» присутствует сильная положительная корреляция. Ошибка прогноза цен закрытия акций компании «Газпром» варьируется от 1,65% до 5% для всех построенных моделей, что говорит о хорошем качестве прогнозирования.

3. Если обучать сети одним и тем же алгоритмом, то в большинстве случаев ошибка прогноза на тестовой выборке SBER колеблется около одного значения – 0,7%, при этом на точность прогноза не влияет ни количество нейронов в скрытом слое, ни количество нейронов, подаваемых на вход. Этот факт свидетельствует о том, что сети с рассматриваемой архитектурой являются малопригодными для регрессионных задач.

Результаты, полученные на большой выборке, полностью совпадают с результатами, представленными выше. Наше предположение о том, что с увеличением числа значений для обучающей выборке увеличится и точность прогноза, не оправдалось.

- ***Прогнозирование направления движения цены (Двухзначная классификация «Рост/Спад»):***

Результаты прогнозирования на большой выборке:

1. Сеть с архитектурой 20-8-2 (гиперболическая функция активации) хорошо классифицирует направление цены акции – процент правильной классификации на обучающей выборке составляет 76 %, а на тестовой выборке – 60 %. В данном случае, мы можем быть уверены, что данный способ принятия решения отличается от подбрасывания монетки.

2. Большинство построенных сетей имеют процент правильной классификации около 60% и выше, что говорит о том, что сети с данной архитектурой можно использовать для решения задачи двухзначной классификации.

На малой выборке процент правильной классификации построенных сетей составляет чуть больше 50%, что говорит о том, что в данном случае объёма выборки, используемой для обучения, недостаточно для получения хорошо прогнозирующих нейросетевых моделей.

Используя трехзначную классификацию «Рост/Нейтрально/Спад», мы получили неудовлетворительные результаты – у всех построенных сетей процент правильной классификации чуть больше 50%. Данный результат нельзя признать положительным, следовательно, сети данной архитектуры являются малопригодными для задачи трехзначной классификации.

4 Финансовый менеджмент, ресурсоэффективность и ресурсосбережение

Целью дипломной работы является построение прогноза цен закрытия акций ведущих российских компаний с использованием нейронных сетей.

Целью раздела «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение» является оценка прогнозирования финансовых временных рядов с использованием нейронных сетей с позиции конкурентоспособности и ресурсоэффективности.

Для достижения поставленной цели необходимо решить следующие задачи:

1. Определить потенциальных потребителей результатов исследования;
2. Выявить сильные и слабые стороны научно-исследовательского проекта, а также его возможности и вероятные угрозы при помощи SWOT-анализа;
3. Оценить степень готовности научного проекта к коммерциализации;
4. Определить заинтересованные стороны и ограничения/допущения научно-технического исследования; сформулировать цель и ожидаемые результаты проекта;
5. Определить структуру и трудоемкость выполнения работ, разработать график проведения научного исследования;
6. Рассчитать бюджет научно-технического исследования;
7. Определить риск возникновения неопределённых событий при выполнении НИИ, которые могут повлечь за собой нежелательные эффекты.

4.1 Предпроектный анализ

4.1.1 Потенциальные потребители результатов исследования

Для анализа потребителей результатов исследования необходимо рассмотреть целевой рынок и провести его сегментирование.

Целевой рынок – сегменты рынка, на котором будет продаваться в

будущем разработка. В свою очередь, сегмент рынка – это особым образом выделенная часть рынка, группы потребителей, обладающих определенными общими признаками.

Сегментирование – это разделение покупателей на однородные группы, для каждой из которых может потребоваться определенный товар (услуга).

Задача прогнозирования финансовых временных рядов была и остается актуальной, поскольку предсказание является необходимым элементом любой инвестиционной деятельности, ведь сама идея инвестирования – вложения денег с целью получения дохода в будущем – основывается на идеи прогнозирования будущего.

Исследование, проведенное в данной работе, имеет непосредственное отношение к инвестициям. Потенциальными потребителями результатов исследования могут быть как инвесторы, владеющие акциями, так и банки, и банковские организации. Также данными исследованиями могут воспользоваться государственные учреждения, интернет-ресурсы и другие связанные с финансовыми инвестициями организации.

В настоящее время профессиональные участники рынка используют различные методы прогнозирования финансовых временных рядов, основные из них:

- 1) Экспертные методы прогнозирования. Самый распространенный метод из группы экспертных методов – метод Дельфи. Суть метода заключается в сборе мнений различных экспертов и их обобщение в единую оценку.

- 2) Экономико-математические методы. Методы из этой группы базируются на создании моделей исследуемого объекта. Экономико-математическая модель — это определенная схема, путь развития рынка ценных бумаг при заданных условиях. При прогнозировании финансовых временных рядов используют статистические, динамические, микро- макро-, линейные, нелинейные, глобальные, локальные, отраслевые,

оптимизационные методы.

3) Технический анализ. Прогнозирование изменений цен в будущем на основе анализа изменений цен в прошлом. Нейронные сети можно отнести к методам технического анализа, т.к. они тоже пытаются выявить закономерности в развитие ряда, обучаясь на его исторических данных.

Таблица 7 – Карта сегментирования рынка услуг по методам прогнозирования

		Методы прогнозирования		
		Экспертные методы прогнозирования	Экономико-математические	Технический анализ
Размер компании	Крупные			
	Средние			
	Мелкие			

Фирма А



Фирма Б



Таким образом, мы определили потенциальных потребителей результатов исследования, а именно – результаты данной работы будут наиболее привлекательны преимущественно для мелких компаний, частных инвесторов и акционеров.

4.1.2 SWOT-анализ

SWOT – Strengths (сильные стороны), Weaknesses (слабые стороны), Opportunities (возможности) и Threats (угрозы) – представляет собой комплексный анализ научно-исследовательского проекта. SWOT-анализ применяют для исследования внешней и внутренней среды проекта.

Разработанная для данного исследования матрица SWOT представлена в таблице 8.

Таблица 8 – Матрица SWOT

	Сильные стороны научно-исследовательского проекта: 1. Высокая прогностическая способность модели	Слабые стороны научно-исследовательского проекта: 1. Длительность вычислений 2. Малая распространённость на рынке
Возможности: 1. Высокий спрос на нейросетевые модели со стороны потребителей. 2. Использование модели для любых финансовых временных рядов (широкий спектр применения)	<ul style="list-style-type: none"> • Высокое качество получаемых результатов вкуче с высоким спросом на нейросетевые модели позволят быстро занять свою нишу на рынке. 	Благодаря высокому спросу можно упростить алгоритм для того, чтобы сократить длительность вычислений.
Угрозы: 1. Наличие множества альтернативных подходов 2. Потеря финансовых средств в случае неверного прогноза	Несмотря на то, что используемые алгоритмы имеют высокую прогностическую способность, любой прогноз не дает 100% гарантии на получение достоверных результатов, в связи с этим есть вероятность потери финансовых активов.	Малая распространённость на рынке подобных моделей позволит эффективнее бороться с конкурентами.

Таким образом, в ходе проведения SWOT-анализа были выявлены сильные и слабые стороны научно-исследовательского проекта, а также его возможности и вероятные угрозы.

4.1.3 Оценка готовности проекта к коммерциализации

На какой бы стадии жизненного цикла не находилась научная разработка полезно оценить степень ее готовности к коммерциализации и выяснить уровень собственных знаний для ее проведения (или завершения).

Для этого необходимо заполнить форму (табл. 9), которая содержит показатели о степени проработанности проекта с позиции коммерциализации и компетенциям разработчика научного проекта.

Оценки степени проработанности научного проекта трактуются следующим образом:

- 1 – не проработано;
- 2 – проработано слабо;
- 3 – выполнено, но качество под сомнением;
- 4 – выполнено качественно;
- 5 – имеется положительное заключение независимого эксперта.

Оценка уровня имеющихся знаний у разработчика определяется в соответствии со следующей системой баллов:

- 1 – не знаком или знаком мало;
- 2 – знаком с теорией;
- 3 – знаком с теорией и практическими примерами применения;
- 4 – знаком с теорией и самостоятельно выполняет;
- 5 – знаком с теорией, выполняет, может консультировать.

Таблица 9 – Бланк оценки степени готовности научного проекта к коммерциализации

№ п/п	Наименование	Степень проработанности научного проекта	Уровень имеющихся знаний у разработчика
1	Определен имеющийся научно-технический задел	5	5
2	Определены перспективные направления коммерциализации научно-технического задела	5	4
3	Определены отрасли и технологии (товары, услуги) для предложения на рынке	5	4
4	Определена товарная форма научно-технического задела для представления на рынок	5	3
5	Определены авторы и осуществлена охрана их прав	5	4

6	Проведена оценка стоимости интеллектуальной собственности	4	4
7	Проведены маркетинговые исследования рынков сбыта	4	3
8	Разработан бизнес-план коммерциализации научной разработки	1	1
9	Определены пути продвижения научной разработки на рынок	4	3
10	Разработана стратегия (форма) реализации научной разработки	1	1
11	Проработаны вопросы международного сотрудничества и выхода на зарубежный рынок	1	1
12	Проработаны вопросы использования услуг инфраструктуры поддержки, получения льгот	1	1
13	Проработаны вопросы финансирования коммерциализации научной разработки	5	4
14	Имеется команда для коммерциализации научной разработки	5	5
15	Проработан механизм реализации научного проекта	5	5
ИТОГО БАЛЛОВ		56	48

Таким образом, по результатам проведенной оценки степени готовности научного проекта к коммерциализации суммарное количество баллов по степени проработанности научного проекта превышает уровень имеющихся знаний у разработчика. Согласно полученным баллам, можно сказать, что перспективность данной разработки выше среднего.

4.1.4 Методы коммерциализации результатов научно-технического исследования

При коммерциализации научно-технических разработок продавец (владелец соответствующих объектов интеллектуальной собственности) преследует определенную цель, которая во многом зависит от того, куда он намерен направить полученный коммерческий эффект. Это может быть получение средств для продолжения научных исследований, одноразовое получение финансовых ресурсов, обеспечение постоянного притока финансовых средств, а также их различные сочетания. В связи с этим необходимо выбрать наиболее подходящий метод коммерциализации и обосновать его целесообразность.

Выделяют следующие методы коммерциализации научных разработок:

торговля патентными лицензиями, передача ноу-хау, инжиниринг, франчайзинг и пр.

Перспективность данного научного исследования выше среднего, однако еще не все аспекты глубоко изучены и проработаны.

Таким образом, проанализировав перечисленные методы коммерциализации, успешному продвижению проекта на данной стадии, на которой находится научный проект, соответствует торговля патентными лицензиями, поскольку степень проработанности проекта и уровня знаний разработчика будет достаточно для реализации данного метода.

4.2 Инициация проекта

Группа процессов инициации состоит из процессов, которые выполняются для определения нового проекта или новой фазы существующего. В рамках процессов инициации определяются изначальные цели и содержание, фиксируются изначальные финансовые ресурсы. Определяются внутренние и внешние заинтересованные стороны проекта, которые будут взаимодействовать и влиять на общий результат. Данная информация закрепляется в уставе проекта.

Устав проекта документирует бизнес-потребности, текущее понимание потребностей заказчика проекта, а также новый продукт, услугу или результат, который планируется создать.

Заинтересованные стороны проекта представлены в табл. 10, цели и результат проекта – в табл. 11.

Таблица 10 – Заинтересованные стороны проекта

Заинтересованные стороны проекта	Ожидания заинтересованных сторон
<ul style="list-style-type: none"> • Профессорско-преподавательский состав кафедры Высшей математики и математической физики Отделения экспериментальной физики НИ ТПУ • Частные инвесторы • Акционеры • Инвестиционные фонды 	<ul style="list-style-type: none"> • Иметь возможность спрогнозировать цены закрытия акций ведущих российских компаний • Получать высокое качество результатов • Использовать большие объёмы данных

Таблица 11 – Цели и результат проекта

Цели проекта	Спрогнозировать цены закрытия акций ведущих российских компаний с использованием нейронных сетей.
Ожидаемые результаты проекта	Разработан подход к проблеме прогнозирования, в основе которого лежат нейросетевые методы. В работе была определена архитектура нейронной сети, оптимизированы параметры сети, спрогнозированы цены закрытия акций ведущих российских компаний.
Критерии приемки результата проекта	Адекватность полученных результатов
Требования к результату проекта	Требование:
	Поскольку результаты анализа представляют собой прогноз финансовых временных рядов на основе нейросетевых методов, одним из основных требований является эффективность обучения нейронной сети. Она должна быть на уровне не менее 95%.

В данном подразделе мы определили заинтересованные стороны проекта и сформулировали цели и ожидаемый результат НИТ.

4.2.1 Организационная структура проекта

На данном этапе необходимо сформировать рабочую группу (табл. 12), определить роль каждого участника, прописать функции, выполняемые каждым из участников и их трудозатраты в проекте.

Таблица 12 – Рабочая группа проекта

№ п/п	ФИО, основное место работы	Роль в проекте	Функции	Трудозатр. час.
1	Шинкеев М.Л. Доцент отделения экспериментально физики	Руководитель	Составление и утверждение научного задания, календарное планирование работ по теме, оценка эффективности полученных результатов	88
2	Булыкина А.А. Магистрант	Исполнитель	Выполнение поставленной задачи, составление и оформление пояснительной записки к ВКР	728
Итого:				816

Таким образом, мы сформировали рабочую группу проекта, а именно – определили роль каждого участника, прописали функции, выполняемые каждым из участников и их трудозатраты в проекте.

4.2.2 Ограничения и допущения проекта

Ограничения проекта (табл.13) – это все факторы, которые могут послужить ограничением степени свободы участников команды проекта, а также «границы проекта» – параметры проекта или его продукта, которые не будут реализованы в рамках данного проекта.

Таблица 13 – Ограничения проекта

Фактор	Ограничения/допущения
Источник финансирования	НИ ТПУ
Сроки проекта	28.02.2020 – 31.05.2020
Дата утверждения плана управления проектом	28.02.2020
Дата завершения проекта	31.05.2020
Прочие ограничения и допущения	Отсутствуют

Таким образом, мы определили ограничения и допущения проекта.

4.3 Планирование научно-исследовательских работ

Планирование комплекса предполагаемых работ осуществляется в следующем порядке:

- Формирование иерархической структуры работ проекта;
- Определение ключевых (контрольных) событий проекта;
- Построение календарного графика проекта;
- Планирование бюджета научного исследования.

4.3.1 Иерархическая структура работ проекта

Иерархическая структура работ (ИСР) – это детализация укрупненной структуры работ. В процессе создания ИСР структурируется и определяется содержание всего проекта. На рисунке 22 представлена ИСР для выполнения магистерской диссертации.

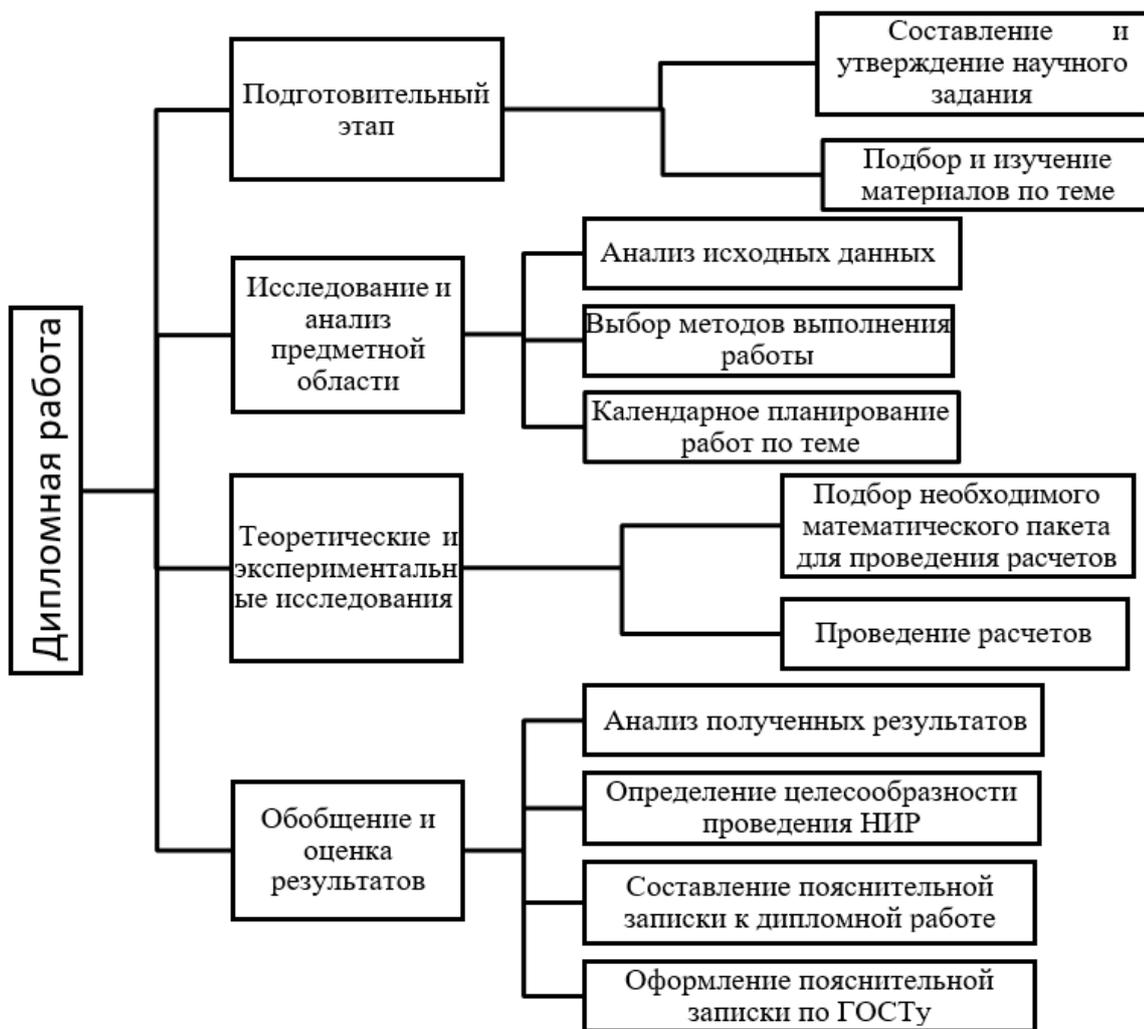


Рисунок 22 – Иерархическая структура работ проекта

Таким образом, мы сформировали иерархическую структуру работ проекта для выполнения данной магистерской диссертации.

4.3.2 Структура работ в рамках научного исследования

Трудоемкость выполнения ВКР оценивается экспертным путем в человеко-днях и носит вероятностный характер, т.к. зависит от множества трудно учитываемых факторов.

Для выполнения научно-исследовательской работы формируется рабочая группа, в состав которой могут входить:

- Руководитель проекта (Р);
- Инженер (дипломник) (И).

На следующем этапе составляется перечень работ в рамках проведения научного исследования, а также проводится распределение исполнителей по

видам работ. Примерный порядок составления этапов и работ, распределение исполнителей по данным видам работ приведен в таблице 14.

Таблица 14 - Комплекс работ по разработке проекта

Основные этапы	№	Содержание работ	Должность исполнителя
Подготовительный	1	Составление и утверждение научного задания	Руководитель Инженер
	2	Подбор и изучение материалов по теме	Инженер
Исследование и анализ предметной области	3	Анализ исходных данных	Инженер
	4	Выбор метода выполнения работы	Руководитель Инженер
	5	Календарное планирование работ по теме	Инженер
Теоретические и экспериментальные исследования	6	Подбор необходимого математического пакета для проведения расчетов	Инженер
	7	Проведение расчетов	Инженер
Обобщение и оценка результатов	8	Анализ результатов работы	Инженер
	9	Определение целесообразности проведения НИР	Руководитель Инженер
	10	Составление пояснительной записке к ВКР.	Инженер
	11	Оформление пояснительной записки к ВКР по ГОСТу.	Инженер

На данном этапе мы составили перечень работ в рамках проведения научного исследования, а также провели распределение исполнителей по видам работ.

4.3.3 Определение трудоемкости выполнения работ и разработка графика проведения научного исследования

Трудовые затраты в большинстве случаев образуют основную часть стоимости разработки, поэтому важным моментом является определение трудоемкости работ каждого из участников научного исследования.

Трудоемкость выполнения научного исследования оценивается

экспертным путем в человеко-днях и носит вероятностный характер, т.к. зависит от множества трудно учитываемых факторов. Для определения ожидаемого (среднего) значения трудоемкости используется следующая формула:

$$t_{\text{ож}i} = \frac{3t_{\text{min}i} + 2t_{\text{max}i}}{5},$$

где $t_{\text{ож}i}$ – ожидаемая трудоемкость выполнения i -й работы, человеко-дни;

$t_{\text{min}i}$ – минимально возможная трудоемкость выполнения заданной i -й работы, человеко-дни;

$t_{\text{max}i}$ – максимально возможная трудоемкость выполнения заданной i -й работы, человеко-дни;

Рассчитаем значение ожидаемой трудоемкости работы.

Установление длительности работ в рабочих днях осуществляется по формуле:

$$T_{\text{P}i} = \frac{t_{\text{ож}i}}{Ч_i},$$

где $T_{\text{P}i}$ – продолжительность одной работы, раб. дн.;

$Ч_i$ – численность исполнителей, выполняющих одновременно одну и ту же работу на данном этапе, чел.

При выполнении дипломных работ студенты в основном становятся участниками сравнительно небольших по объему научных тем. Поэтому наиболее удобным и наглядным является построение ленточного графика проведения научных работ в форме диаграммы Гантта.

Диаграмма Гантта – горизонтальный ленточный график, на котором работы по теме представляются протяженными во времени отрезками, характеризующимися датами начала и окончания выполнения данных работ.

Для удобства построения графика, длительность каждого из этапов работ из рабочих дней следует перевести в календарные дни. Для этого необходимо воспользоваться формулой:

$$T_{ki} = T_{pi} \cdot k_{\text{кал}},$$

где T_{ki} – продолжительность выполнения i -й работы в календарных днях;

T_{pi} – продолжительность выполнения i -й работы в рабочих днях;

$k_{\text{кал}}$ – коэффициент календарности, предназначен для перевода рабочего времени в календарное.

Коэффициент календарности определяется по формуле:

$$k_{\text{кал}} = \frac{T_{\text{кал}}}{T_{\text{кал}} - T_{\text{вых}} - T_{\text{пр}}},$$

где $T_{\text{кал}}$ – количество календарных дней в году;

$T_{\text{вых}}$ – количество выходных дней в году;

$T_{\text{пр}}$ – количество праздничных дней в году.

Рассчитанные значения в календарных днях по каждой работе необходимо округлить до целого числа.

Вычислим коэффициент календарности:

$$k_{\text{кал}} = \frac{366}{366 - 92 - 26} = 1,48$$

Рассчитанные временные показатели были сведены в таблицу 15, представленную ниже.

Таблица 15 – Временные показатели осуществления комплекса работ

№ работ ы	Продолжительность работ			Исполнител и	T_{pi} , человеко -дни	T_{ki} , человеко -дни
	$t_{\min i}$, человеко -дни	$t_{\max i}$, человеко -дни	$t_{ожi}$, человеко -дни			
1	1	5	3	Р, И	2	3
2	11	17	13	И	13	20
3	2	9	5	И	5	7
4	5	7	6	Р, И	3	4
5	1	3	2	И	2	3
6	1	1	1	И	1	1
7	11	17	13	И	13	20
8	4	6	5	И	5	7
9	5	7	6	Р, И	3	4
10	9	11	10	И	10	15
11	2	9	5	И	5	7
Итого:					62	91

На основании таблицы 15 составлен календарный план-график, показывающий продолжительность выполнения работ ВКР. В результате планирования графика, продолжительность работ равна трём месяцам (табл. 16).

Таблица 16 – Календарный план-график выполнения работ
(диаграмма Гантта)

Календарный план-график проведения магистерской диссертации по теме															
№	Наименование работы	Исполнители	Т, дни	Продолжительность выполнения работ, дни											
				Март			Апрель			Май					
				1	2	3	1	2	3	1	2	3			
1	Составление и утверждение ТЗ	Руководитель Инженер	3	■											
2	Подбор и изучение материалов по теме	Инженер	20	■	■	■									
3	Анализ исходных данных	Инженер	7			■									
4	Выбор метода выполнения работы	Руководитель Инженер	4					■							
5	Календарное планирование работ по теме	Инженер	3					■							
6	Подбор необходимого математического пакета для проведения расчетов	Инженер	1					■							
7	Проведение расчетов	Инженер	20					■	■	■					
8	Анализ результатов работы	Инженер	7										■		
9	Определение целесообразности проведения НИР	Руководитель Инженер	4										■		
10	Составление пояснительной записки к ВКР.	Инженер	15										■	■	■
11	Оформление пояснительной записки к ВКР по ГОСТу.	Инженер	7												■

Руководитель
Инженер

Таким образом, мы определили трудоемкость выполнения работ и

разработали календарный план-график проведения магистерской диссертации по теме.

4.3.4 Бюджет научно-технического исследования

При планировании бюджета НТИ должно быть обеспечено полное и достоверное отражение всех видов расходов, связанных с его выполнением. В процессе формирования бюджета НТИ используется следующая группировка затрат по статьям:

- Сырье, материалы (за вычетом возвратных отходов), покупные изделия и полуфабрикаты;
- Основная заработная плата;
- Отчисления на социальные нужды;
- Накладные расходы.

4.3.4.1 Затраты на материалы

Данная статья отражает стоимость всех материалов, используемых при разработке проекта, включая расходы на их приобретение и доставку. Транспортные расходы принимаются в пределах 15-25% от стоимости материалов. В материальные затраты, помимо вышеуказанных, включаются дополнительно затраты на канцелярские принадлежности, диски, картриджи и т.п. Однако их учет ведется в данной статье только в том случае, если в научной организации их не включают в расходы на использование оборудования или накладные расходы.

Материальные затраты, необходимые для данной разработки, заносятся в таблицу 17.

Таблица 17 – Материальные затраты

Наименование	Единица измерения	Количество	Цена за ед., руб.	Затраты на материалы (З _м), руб.
Бумага	Пачка	1	250	250
Картридж для принтера	Шт	1	4000	4000
Канцелярские принадлежности	Шт	1	250	250
Итого:				4500

На данном этапе мы рассчитали материальные затраты, необходимые для проведения научно-технического исследования. Они составляют 4500 руб.

4.3.4.2 Основная заработная плата

Величина расходов по заработной плате определяется исходя из трудоемкости выполняемых работ и действующей системы окладов и тарифных ставок. В состав основной заработной платы включается премия, выплачиваемая ежемесячно из фонда заработной платы в размере 20 – 30 % от тарифа или оклада.

Статья включает основную заработную плату работников, непосредственно занятых выполнением НИТ, (включая премии, доплаты) и дополнительную заработную плату:

$$З_{зп} = З_{осн} + З_{доп},$$

где $З_{осн}$ – основная заработная плата;

$З_{доп}$ – дополнительная заработная плата.

Основная заработная плата ($З_{осн}$) руководителя (лаборанта, инженера) от предприятия (при наличии руководителя от предприятия) рассчитывается по следующей формуле:

$$З_{осн} = З_{дн} \cdot T_p,$$

где $З_{осн}$ – основная заработная плата одного работника;

T_p – продолжительность работ, выполняемых научно-техническим работником, раб. дн.;

$З_{дн}$ – среднедневная заработная плата работника, руб.

Среднедневная заработная плата рассчитывается по формуле:

$$З_{дн} = \frac{З_m \cdot M}{F_d},$$

где $З_m$ – месячный должностной оклад работника, руб.;

M – количество месяцев работы без отпуска в течение года;

F_d – действительный годовой фонд рабочего времени научно-

технического персонала, раб. дн.;

М – количество месяцев работы без отпуска в течение года:

- при отпуске в 24 раб. дня М=11,2 месяца, 5 – дневная неделя;
- при отпуске в 48 раб. дней М = 10,4 месяца, 6-дневная неделя.

Таблица 18 – Баланс рабочего времени

Показатели рабочего времени	Руководитель	Инженер
Календарное число дней	366	366
Количество нерабочих дней	92	92
– выходные дни	26	26
– праздничные дни		
Потери рабочего времени	48	48
– отпуск	–	–
– невыходы по болезни		
Действительный годовой фонд рабочего времени	200	200

Месячный должностной оклад работника:

$$З_{\text{м}} = З_{\text{б}} \cdot (k_{\text{пр}} + k_{\text{д}}) \cdot k_{\text{р}},$$

где $Z_{\text{б}}$ – базовый оклад, руб.;

$k_{\text{пр}}$ – премиальный коэффициент, определяется Положением об оплате труда;

$k_{\text{д}}$ – коэффициент доплат и надбавок составляет примерно 0,2 – 0,5 (в НИИ и на промышленных предприятиях – за расширение сфер обслуживания, за профессиональное мастерство, за вредные условия: определяется Положением об оплате труда);

$k_{\text{р}}$ – районный коэффициент, равный 1,3 (для г. Томска).

Результат расчетов заработных плат представлен в таблице 19.

Таблица 19 – Расчёт основной заработной платы

Исполнители	$Z_{\text{б}}$, руб	$k_{\text{р}}$	$Z_{\text{м}}$, руб	$Z_{\text{дн}}$, руб	$T_{\text{р}}$, дни	$Z_{\text{осн}}$, руб
Руководитель	35120	1,3	45656	2374,11	11	26115,21
Инженер	12000	1,3	15600	811,2	91	73819,2
Итого:						99934,41

Таким образом, мы рассчитали основную заработную плату

исполнителей данного научно-технического исследования. Общая сумма заработной платы участников проекта составляет 99934,41 руб.

4.3.4.3 Отчисления во внебюджетные фонды

Отчисления во внебюджетные фонды являются обязательными по установленным законодательством Российской Федерации нормам органам государственного социального страхования (ФСС), пенсионного фонда (ПФ) и медицинского страхования (ФФОМС) от затрат на оплату труда работников.

Величина отчислений во внебюджетные фонды определяется исходя из следующей формулы:

$$C_{\text{внеб}} = k_{\text{внеб}} \cdot (Z_{\text{осн}} + Z_{\text{доп}}),$$

где $k_{\text{внеб}}$ – коэффициент отчислений на уплату во внебюджетные фонды (пенсионный фонд, фонд обязательного медицинского страхования и пр.).

Коэффициент отчислений на уплату во внебюджетные фонды равен 30,2 %.

Отчисления во внебюджетные фонды представлены в таблице 20.

Таблица 20 – Отчисления во внебюджетные фонды

Исполнители	Основная ЗП, руб
Руководитель	26115,21
Инженер	73819,2
Коэффициент отчислений во внебюджетные фонды	0,302
Итого:	30180,19

В данном подразделе мы рассчитали отчисления во внебюджетные фонды, которые являются обязательными по установленным законодательством Российской Федерации нормам органам государственного социального страхования (ФСС), пенсионного фонда (ПФ) и медицинского страхования (ФФОМС) от затрат на оплату труда работников. Сумма отчислений во внебюджетные фонды составляет 30180,19 руб.

4.3.4.4 Накладные расходы

Накладные расходы учитывают прочие затраты организации, не попавшие в предыдущие статьи расходов: печать и ксерокопирование материалов исследования, оплата услуг связи, электроэнергии, почтовые и

телеграфные расходы и т.д.

Так как работа производилась только с использованием персонального компьютера, все накладные расходы составляет плата за электроэнергию и интернет. В расчётах будем учитывать, что мощность компьютера руководителя равна $P_{рук} = 0.1$ кВт, мощность компьютера исполнителя — $P_{исп} = 0.05$ кВт. Также учитываем одинаковую плату за интернет $S_{и} = 350$ руб/мес. Тогда при 8-часовом рабочем дне накладные расходы составляют:

$$C_{накл} = 8 \cdot (T_{рук} \cdot P_{рук} + T_{исп} \cdot P_{исп}) \cdot S_{эл} + T_p/30 \cdot S_{и},$$

где $S_{эл} = 5.8$ руб / кВт · ч — удельная плата за электроэнергию.

Следовательно, $C_{накл}$ составляют 1452,16 руб.

Таким образом, мы рассчитали плату за электроэнергию и интернет, которые и составляют накладные расходы. Итоговая сумма накладных расходов равна 1452,16 руб.

4.3.4.5 Формирование бюджета затрат НТИ

Рассчитанная величина затрат научно-исследовательской работы является основой для формирования бюджета затрат проекта, который при формировании договора с заказчиком защищается научной организацией в качестве нижнего предела затрат на разработку научно-технической продукции. Определение бюджета затрат на научно-исследовательский проект приведен в таблице 21.

Таблица 21 – Расчет бюджета затрат НТИ

Наименование статьи	Сумма, руб.
1. Материальные затраты НТИ	4500
2. Затраты по основной заработной плате исполнителей темы	99934,41
3. Отчисления во внебюджетные фонды	30180,19
4. Накладные расходы	1452,16
5. Бюджет затрат НТИ	136066,76

Подводя итог, мы можем сделать вывод, что бюджет затрат научно-технического исследования равен 136066,76 руб.

4.4 Реестр рисков проекта

Во время проекта существует риск возникновения неопределённых событий, которые могут повлечь за собой нежелательные эффекты. Для таких событий составлен реестр рисков, содержащий в себе общую информацию о них (табл. 22) Вероятность наступления и влияние определённого риска оцениваются по пятибалльной шкале. Уровень риска может быть высокий, средний или низкий в зависимости от вероятности наступления и степени влияния риска.

Таблица 22 – Реестр рисков

Риск	Потенциальное воздействие	Вероятность наступления	Влияние	Уровень	Способы смягчения	Условия наступления
Управление проектом	Некорректный сбор информации	3	5	Высокий	Разделение обязанностей	Несогласованность действие
Технический	Некорректные результаты	3	5	Высокий	Чёткое планирование	Несогласованность действий
Внешний	Несоответствие плану	2	2	Низкий	Резервное время	Отсутствие данных

По результатам данного подраздела можно сделать вывод, что риск возникновения неопределённых событий, которые могут повлечь за собой нежелательные эффекты, существует, но вероятность наступления его маловероятна.

4.5 Выводы по разделу

Выводы по главе «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»:

1. Определены потенциальные потребители результатов исследования – результаты данной работы будут наиболее привлекательны преимущественно для мелких компаний, частных инвесторов и акционеров.

2. Выявлены сильные и слабые стороны научно-исследовательского проекта, а также его возможности и вероятные угрозы при помощи SWOT-анализа:

- Высокое качество получаемых результатов вкупе с высоким спросом на нейросетевые модели позволит быстро занять свою нишу на рынке.
- Рассматриваемые методы могут применяться для любых временных рядов, что позволяет расширить круг потенциальных клиентов.
- Малая распространённость на рынке подобных моделей позволит эффективнее бороться с конкурентами.
- Несмотря на то, что используемые алгоритмы имеют высокую прогностическую способность, любой прогноз не дает 100% гарантии на получение достоверных результатов, в связи с этим есть вероятность потери финансовых активов.

3. Определена степень готовности научного проекта к коммерциализации: согласно полученным результатам, можно сказать, что перспективность данной разработки выше среднего. Выбран метод коммерциализации результатов НИТ: торговля патентными лицензиями.

4. Определены заинтересованные стороны проекта: профессорско-преподавательский состав кафедры ВММФ отделения экспериментальной физики НИ ТПУ, частные инвесторы, акционеры, инвестиционные фонды. Ограничениями научно-технического исследования являются сроки выполнения. Сформулированы цели и ожидаемые результаты проекта.

5. В ходе планирования научно-исследовательских работ определены структура и перечень работ, выполняемых рабочей группой. В данном случае рабочая группа состоит из двух человек: руководитель и инженер. Согласно составленному плану работ длительность трудовой занятости сотрудников научно-исследовательского проекта составила 91 день. На основе временных показателей по каждой из произведенных работ был построен календарный план-график, построенный на основе диаграммы Ганта, по которому можно увидеть, что самые продолжительные по времени работы – это подбор и изучение материалов по теме (20 дней) и проведение

расчетов (20 дней).

6. Бюджет научно-технического исследования составил 136066,76 руб. Он состоит из материальных затрат (4500 руб.), затрат на оплаты труда (99934,41руб.), отчислений во внебюджетные фонды 30180,19 руб.) и накладных расходов (1452,16 руб).

7. Определен риск возникновения неопределённых событий при выполнении НТИ: риск возникновения неопределённых событий, которые могут повлечь за собой нежелательные эффекты, существует, но вероятность наступления его маловероятна.

Точность прогнозирования у разных инвестбанков разная: на нее влияют и профессионализм аналитика, и форсмажоры, которые он, конечно, не может предусмотреть. Точность прогнозирования аналогичной разработки колеблется в пределах 80 – 90%. Мы же, в свою очередь, хотим предложить разработку, у которой точность прогнозирования будет не ниже 95% на каждые 90% или более промежутков времени.

Стоимость аналогичной разработки 194400 руб., в нашем случае – стоимость научно-технического исследования равна 136066,76 руб. Более высокая точность прогнозирования с наименьшей стоимостью разработки данного НТИ подтверждают эффективность исследования.

5. Социальная ответственность

Задача прогнозирования поведения сложных динамических систем, особенно в экономике и социальной сфере является трудноформализуемой. Прогноз таких систем должен опираться почти исключительно на выявлении скрытых закономерностей в накопленных данных. Предсказание финансовых временных рядов – типичный пример такого рода задач. Цель работы – построить прогноз финансовых временных рядов с использованием нейронных сетей. В данной работе разработан подход к проблеме прогнозирования, в основе которого лежат нейросетевые методы. Они отличаются своей способностью устанавливать нелинейные связи между будущими и фактическими значениями и хорошей масштабируемостью. В работе была определена архитектура нейронной сети, оптимизированы параметры сети, спрогнозированы цены закрытия акций ведущих российских компаний.

Область применения данного исследования: фондовые рынки. Научно-техническое исследование, проведённое в данной работе, имеет непосредственное отношение к инвестициям. Потенциальными потребителями результатов исследования могут быть: инвесторы, владеющие акциями; банки, банковские организации.

Данная работа была проведена за компьютером, или персональной электронной вычислительной машиной (ПЭВМ). Поэтому в рамках текущего раздела будут рассмотрены соответствующие вопросы, связанные со следующими компонентами безопасности рабочего пространства магистранта:

- выявление и изучение вредных и опасных производственных факторов при работе с ПЭВМ;
- определение способов снижения действия вредных факторов до безопасных пределов или по возможности до полного их исключения;
- техника производственной безопасности;
- безопасность окружающей среды.

Характеристика помещения, где была разработана магистерская работа: ширина комнаты составляет $b = 4\text{ м}$, длина $a = 6\text{ м}$, высота $H = 2,8\text{ м}$. Тогда площадь помещения будет составлять $S = ab = 24\text{ м}^2$, объем $V = abh = 78\text{ м}^3$. В помещении имеется окно, через которое осуществляется вентиляция помещения. В зимнее время помещение отапливается, что обеспечивает достаточное, постоянное и равномерное нагревание воздуха. В помещении используется комбинированное освещение - искусственное и естественное.

5.1 Правовые и организационные вопросы обеспечения безопасности

С каждым годом все большее применение находят электронно-вычислительные машины (ЭВМ) как на производстве, так и для научно-исследовательских и конструкторских работ, а также в сфере управления и образования. Компьютеры уже завоевали свое место на предприятиях, в организациях, офисах и даже в домашних условиях. Однако компьютер является источником вредного воздействия на организм человека, а, следовательно, и источником профессиональных заболеваний. Это предъявляет к каждому пользователю персонального компьютера требование – знать о вредном воздействии персональных электронных вычислительных машин (ПЭВМ) на организм человека и необходимых мерах защиты от этих воздействий.

Рабочая поверхность имеет высоту $0,75\text{ м}$. Конструкция стола соответствует нормам СН 245-78. Стол оборудуется специальными ящиками с необходимыми для работы предметами. Электроснабжение сети переменного напряжения 220 В . Помещение без повышенной опасности в отношении поражения человека электрическим током по ГОСТ 12.1.038-82 ССБТ[1].

Основными элементами рабочего места являются стол и стул, т.к. рабочим положением является положение сидя. Рациональная планировка рабочего места определяет порядок и местоположение предметов, в особенности тех, которые для работ необходимы чаще.

Основные зоны досягаемости рук в горизонтальной плоскости показаны на рис. 23:

- зона максимальной досягаемости рук;
- зона досягаемости пальцев при вытянутой руке;
- зона лёгкой досягаемости ладони;
- оптимальное пространство для грубой ручной работы;
- оптимальное пространство для тонкой ручной работы.

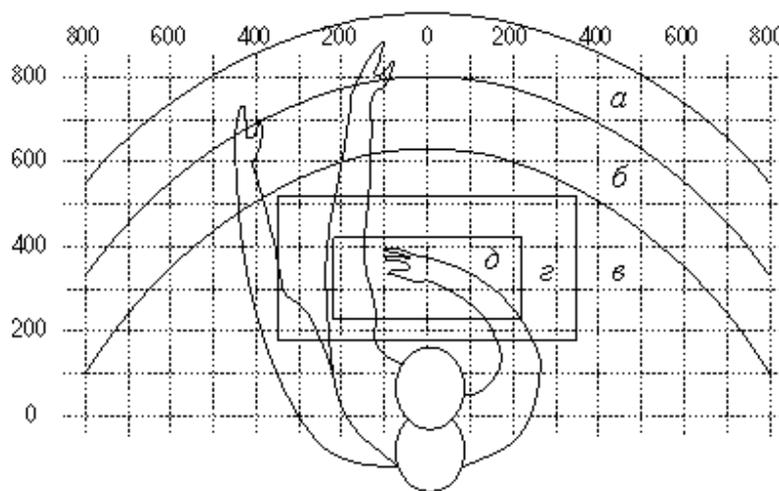


Рисунок 23 – Зоны досягаемости рук в горизонтальной плоскости

В соответствии с этим, принимается следующее оптимальное размещение предметов труда и документации в зонах досягаемости:

1. дисплей размещается в зоне **а** (в центре);
2. системный блок размещается в предусмотренной нише стола;
3. клавиатура - в зоне **г/д**;
4. манипулятор «компьютерная мышь» - в зоне **в** справа;
5. сканер в зоне **а/б** (слева);
6. принтер находится в зоне **а** (справа);
7. документация, необходимая при работе в зоне **в**, а в выдвижных ящиках стола – литература, используемая не постоянно.

При проектировании письменного стола должны быть учтены следующие требования:

1. Рекомендованная высота рабочей поверхности стола в пределах

680 – 800 мм. Высота рабочей поверхности, на которую устанавливается клавиатура, должна быть 650 мм. Рабочий стол должен быть шириной не менее 700 мм и длиной не менее 1400 мм. Должно иметься пространство для ног высотой не менее 600 мм, шириной — не менее 500 мм, глубиной на уровне колен — не менее 450 мм и на уровне вытянутых ног — не менее 650 мм.

2. Рабочее кресло должно быть подъёмно-поворотным и регулируемым по высоте и углам наклона сиденья и спинки, а также расстоянию спинки до переднего края сиденья. Рекомендуется высота сиденья над уровнем пола 420– 550 мм. Конструкция рабочего кресла должна обеспечивать: ширину и глубину поверхности сиденья не менее 400 мм.

3. Монитор должен быть расположен на уровне глаз оператора на расстоянии 500–600 мм. Согласно нормам, угол наблюдения в горизонтальной плоскости должен быть не более 45° к нормали экрана. Лучше если угол обзора будет составлять 30°. Кроме того должна быть возможность выбирать уровень контрастности и яркости изображения на экране. Должна предусматриваться возможность регулирования экрана.

4. Рабочие места с компьютерами должны размещаться так, чтобы расстояние от экрана одного монитора до тыла другого было не менее 2,0 м, а расстояние между боковыми поверхностями мониторов - не менее 1,2 м.

Общие требования к организации и оборудованию рабочих мест с ПЭВМ даны в СанПиН 2.2.2/2.4.1340-03[2] и ГОСТ 12.2.032-78 ССБТ[3]. Все параметры рабочего стола удовлетворяют нормативным требованиям.

5.2 Производственная безопасность

В данном подразделе анализируются вредные и опасные факторы, которые могут возникать при проведении исследования в офисе.

Для идентификации потенциальных факторов необходимо использовать ГОСТ 12.0.003-2015 «Опасные и вредные производственные факторы. Классификация» [4]. Перечень опасных и вредных факторов, характерных для проектируемой производственной среды представлены в

таблице 23.

Таблица 23 - Возможные опасные и вредные факторы

Факторы (ГОСТ 12.0.003-2015)	Этапы работ			Нормативные документы
1. Отклонение показателей микроклимата	+	+	+	1. СанПиН 2.2.4.548–96. Гигиенические требования к микроклимату производственных помещений.
2. Недостаточная освещённость рабочей зоны	+	+	+	2. СП 52.13330.2016 Естественное и искусственное освещение. Актуализированная редакция СНиП 23-05-95*
3. Превышение уровня шума	+	+	+	3. ГОСТ 12.1.003-2014 ССБТ. Шум. Общие требования безопасности.
4. Повышенный уровень электромагнитных излучений	+	+	+	4. ГОСТ 12.1.006-84 ССБТ. Электромагнитные поля радиочастот. Общие требования безопасности.
5. Повышенное значение напряжение в электрической цепи, замыкание которой может произойти через тело человека	+	+	+	5. ГОСТ 12.1.038-82 ССБТ. Электробезопасность. Предельно допустимые уровни напряжений прикосновения и токов.
6. Психофизические факторы	+	+	+	6. ГОСТ 12.2.032-78 ССБТ. Рабочее место при выполнении работ сидя. Общие эргономические требования.

5.3 Анализ опасных и вредных производственных факторов

Вредным называется производственный фактор, воздействие которого на работающего в определенных условиях приводит к заболеванию или снижению работоспособности. При изменении уровня и времени воздействия вредные производственные факторы могут стать опасными. Опасными считаются производственные факторы, воздействие которых на работающего в конкретных условиях может привести к травмам, а также другим внезапным резким ухудшениям здоровья.

Факторы, перечисленные в таблице 1, могут привести к ухудшению здоровья пользователя, а также к профессиональным заболеваниям.

5.3.1 Отклонение показателей микроклимата

Микроклимат производственных помещений – это климат внутренней среды помещений, который определяется действующими на организм

человека сочетаниями температур воздуха и поверхностей, относительной влажности воздуха, скорости движения воздуха и интенсивности теплового излучения.

Нормы оптимальных и допустимых показателей микроклимата при работе с ЭВМ устанавливает СанПиН 2.2.4.548–96 [5]. Эти нормы устанавливаются в зависимости от времени года, характера трудового процесса и производственного помещения. Все категории работ разграничиваются на основе интенсивности энергозатрат организма в ккал/ч (Вт). Работа математика-программиста, выполняемая сидя и сопровождающаяся незначительным физическим напряжением, относится к категории Ia – работа с интенсивностью энергозатрат до 120 ккал/ч (до 139 Вт). Для данной категории допустимые нормы микроклимата представлены в таблице 24.

Таблица 24 – Допустимые нормы микроклимата в рабочей зоне производственных помещений

Сезон года	Категория тяжести выполняемых работ	Температура, °C		Относительная влажность, %		Скорость движения воздуха, м/сек	
		Фактическое значение	Допустимое значение	Фактическое значение	Допустимое значение	Фактическое значение	Допустимое значение
Холодный	Ia	(22÷24)	(19÷24)	55	(15÷75)	0,1	≤0,1
Теплый	Ia	(23÷25)	(20÷28)	55	(15÷75)	0,1	≤0,2

Анализируя таблицу 24, можно сделать вывод, что в рассматриваемом помещении параметры микроклимата соответствуют нормам СанПиН. Допустимый уровень микроклимата помещения обеспечивается системой водяного центрального отопления и естественной вентиляцией.

В производственных помещениях, где допустимые нормативные величины микроклимата поддерживать не представляется возможным, необходимо проводить мероприятия по защите работников от возможного перегревания и охлаждения.

5.3.2 Недостаточная освещённость рабочей зоны

Освещение — важнейший фактор создания нормальных условий труда для работника. В случае недостатка освещённости рабочего места у человека уменьшается острота зрения, происходит утомление организма в целом, что приводит к снижению производительности труда и увеличению опасности заболеваний. Оценка освещённости рабочей зоны проводится в соответствии СП 52.13330.2016 Естественное и искусственное освещение. Актуализированная редакция СНиП 23-05-95* [6].

Согласно санитарно-гигиеническим требованиям, рабочее место с ПЭВМ должно освещаться комбинированным освещением. Естественное освещение поступает в помещение через одно окно в светлое время суток. Искусственное освещение обеспечивается за счет люминесцентных ламп типа ЛД.

Расчёт общего равномерного искусственного освещения горизонтальной рабочей поверхности выполняется методом коэффициента светового потока, учитывающим световой поток, отражённый от потолка и стен. Длина помещения $a = 6\text{ м}$, ширина $b = 4\text{ м}$, высота $H = 2,8\text{ м}$. Высота рабочей поверхности над полом $h_p = 0,75\text{ м}$. Интегральным критерием оптимальности расположения светильников является величина λ , которая для люминесцентных светильников с защитной решёткой лежит в диапазоне 1,1–1,3. Выбираем лампу дневного света ЛД-40, световой поток которой равен $\Phi_{\text{лд}} = 2300 \text{ Лм}$.

Выбираем светильники с люминесцентными лампами типа ОДОР-2-40. Этот светильник имеет две лампы мощностью 40 Вт каждая, длина светильника равна 1227 мм, ширина – 265 мм.

На первом этапе определим значение индекса освещённости i .

$$i = \frac{S}{(a+b) \cdot h},$$

(1)

где S – площадь помещения;

h – расчетная высота подвеса светильника, м;

a и b – длина и ширина помещения, м.

Высота светильника над рабочей поверхностью h :

$$h = H - h_p - h_c = 2,8 - 0,75 - 0,3 = 1,55, \quad (2)$$

где H - высота помещения, м;

h_p - высота рабочей поверхности, м;

В результате проведенных расчетов, индекс освещенности i равен:

$$i = \frac{S}{(a+b) \cdot h} = \frac{24}{(4+6) \cdot 1,55} = 1,5$$

Расстояние между соседними светильниками или рядами определяется по формуле:

$$L = \lambda \cdot h = 1,1 \cdot 1,55 = 1,6 \text{ м}$$

В помещении, где проводилось научно-техническое исследование, всего насчитывалось 12 светильников. Учитывая, что в каждом светильнике установлено две лампы, общее число ламп в помещении $N = 24$.

Расстояние от крайних светильников или рядов до стены определяется по формуле:

$$l = \frac{L}{3} = \frac{300}{3} = 100 \text{ мм}$$

Размещаем светильники в три ряда. План помещения и размещения светильников с люминесцентными лампами представлен на рис. 3.

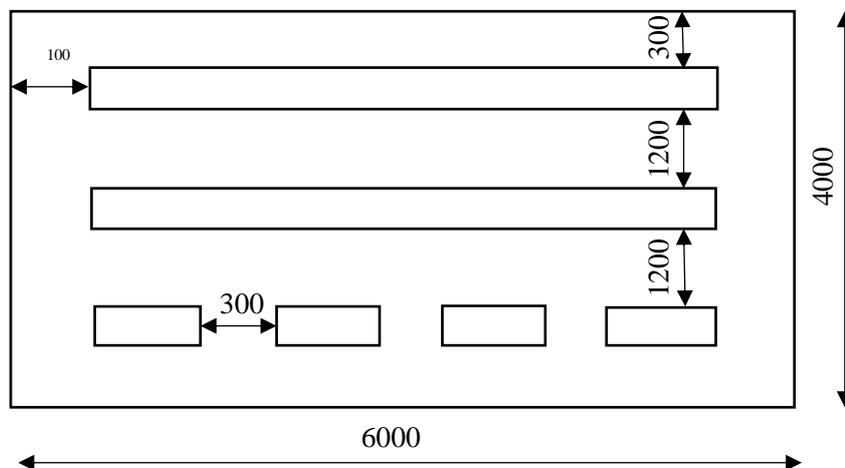


Рисунок 24 – План помещения и размещения светильников с люминесцентными лампами (разметка в мм)

Световой поток лампы определяется по формуле:

$$\Phi = \frac{E_n \cdot S \cdot K_z \cdot Z}{N \cdot \eta}, \quad (3)$$

где E_n – нормируемая минимальная освещённость по СНиП 23-05-95, лк;

S – площадь освещаемого помещения, m^2 ;

K_z – коэффициент запаса, учитывающий загрязнение светильника (источника света, светотехнической арматуры, стен и пр., т. е. отражающих поверхностей), наличие в атмосфере цеха дыма, пыли;

Z – коэффициент неравномерности освещения, отношение E_{cp}/E_{min} .

Для люминесцентных ламп при расчётах берётся равным 1,1;

N – число ламп в помещении;

η – коэффициент использования светового потока.

Данное помещение относится к типу помещения со средним выделением пыли, в связи с этим $K_z = 1,5$; состояние потолка – свежепобеленный, поэтому значение коэффициента отражения потолка $p_n = 70$; состояние стен – побеленные бетонные стены, поэтому значение коэффициента отражения стен $p_c = 50$. Коэффициент использования светового потока, показывающий какая часть светового потока ламп попадает на рабочую поверхность, для светильников типа ОДОР с люминесцентными лампами при $p_n = 70\%$, $p_c = 50\%$ и индексе помещения $i = 1,5$ равен $\eta = 0,47$.

Нормируемая минимальная освещенность при использовании ЭВМ и одновременной работе с документами должна быть равна 600 лк.

$$\Phi = \frac{E_n \cdot S \cdot K_z \cdot Z}{N \cdot \eta} = \frac{600 \cdot 24 \cdot 1,5 \cdot 1,1}{24 \cdot 0,47} = 2106 \text{ Лм}$$

Для люминесцентных ламп с мощностью 40 Вт и напряжением сети 220 В, стандартный световой поток ЛД равен 2300 Лм.

$$-10\% \leq \frac{\Phi_{ЛД} - \Phi_{л.расч}}{\Phi_{ЛД}} \cdot 100\% \leq 20\%$$

$$\frac{2300 - 2106}{2300} \cdot 100\% = 8,43\%$$

$$-10\% \leq 8,43\% \leq 20\%$$

Таким образом необходимый световой поток светильника не выходит за пределы требуемого диапазона.

5.3.3 Превышение уровня шума

Предельно допустимый уровень (ПДУ) шума – это уровень фактора, который при ежедневной (кроме выходных дней) работе, но не более 40 часов в неделю в течение всего рабочего стажа, не должен вызывать заболеваний или отклонений в состоянии здоровья, обнаруживаемых современными методами исследований в процессе работы или в отдаленные сроки жизни настоящего и последующих поколений. Соблюдение ПДУ шума не исключает нарушения здоровья у сверхчувствительных лиц.

Допустимый уровень шума ограничен ГОСТ 12.1.003-2014 ССБТ [7] и СН 2.2.4/2.1.8.562–96 [8]. Уровень шума на рабочем месте математиков-программистов не должен превышать 50дБА, а в залах обработки информации на вычислительных машинах - 65дБА.

При значениях выше допустимого уровня необходимо предусмотреть средства коллективной защиты (СКЗ) и средства индивидуальной защиты (СИЗ):

1. СКЗ

- устранение причин шума или существенное его ослабление в источнике образования;

- изоляция источников шума от окружающей среды средствами звуко- и виброизоляции, звуко- и вибропоглощения;

- применение средств, снижающих шум и вибрацию на пути их распространения;

2. СИЗ

- применение спецодежды, спецобуви и защитных средств органов слуха: наушники или беруши.

Защита от шумов – заключение вентиляторов в защитный кожух и установление их внутри корпуса ЭВМ. Для снижения уровня шума стены и потолок помещений, где установлены компьютеры, могут быть облицованы звукопоглощающими материалами (например, базальтовой ватой или пенопластом) с максимальными коэффициентами звукопоглощения в области частот 63 - 8000 Гц.

Ноутбук, на котором была выполнена магистерская диссертация, имеет следующие характеристики: процессор Core i5, оперативная память 8 Гб, система Microsoft Windows 10, экран с диагональю 13,3" и разрешением 2560 × 1440. Уровень шума вентилятора у данного ПЭВМ составляет примерно 35 дБ, что не превышает предельно допустимое значение: 50дБА.

5.3.4 Повышенный уровень электромагнитных излучений

Электромагнитное поле (ЭМП) обладает способностью биологического, специфического и теплового воздействия на организм человека, что может повлечь следующие последствия: биохимические изменения в клетках и тканях; нарушения условно-рефлекторной деятельности, снижение биоэлектрической активности мозга, изменения межнейронных связей, отклонения в эндокринной системе; вследствие перехода ЭМП в тепловую энергию может наблюдаться повышение температуры тела, локальный избирательный нагрев тканей и так далее.

Согласно ГОСТ 12.1.006-84 ССБТ [9]:

1. Напряженность ЭМП на расстоянии 50 см вокруг ВДТ по электрической составляющей должна быть не более:

- в диапазоне частот 5Гц-2кГц – 25В/м;
- в диапазоне частот 2кГц/400кГц – 2,5В/м.

2. Плотность магнитного потока должна быть не более:

- в диапазоне частот 5Гц-2кГц – 250нТл;
- в диапазоне частот 2кГц/400кГц – 25нТл.

Среди средств защиты от ЭМП выделяют следующие:

1. Организационные мероприятия — выбор рациональных режимов

работы оборудования, ограничение места и времени нахождения персонала в зоне воздействия ЭМП, т.е. защита расстоянием и временем;

2. Инженерно-технические мероприятия, включающие рациональное размещение оборудования, использование средств, ограничивающих поступление электромагнитной энергии (поглотители мощности, экранирование и т.п.);

3. Лечебно-профилактические мероприятия в целях предупреждения, ранней диагностики и лечения здоровья персонала;

4. Средства индивидуальной защиты, к которым относятся защитные очки, щитки, шлемы, защитная одежда, выполненная из металлизированной ткани (кольчуга). При этом следует отметить, что использование СИЗ возможно при кратковременных работах и является мерой аварийного характера.

Персональный компьютер (ПК) имеет сразу два источника электромагнитного излучения: монитор и системный блок. Основной энергетический спектр этих полей находится в диапазоне до 1 кГц. В нашем случае напряженность ЭМП на расстоянии 50 см составляет 0,5 В/м, а плотность магнитного потока 5 нТл, что не превышает предельно допустимые значения, определённые в ГОСТ 12.1.006-84 ССБТ.

5.3.5 Повышенное значение напряжение в электрической цепи, замыкание которой может произойти через тело человека

Помещение, где была разработана магистерская работа, принадлежит к категории помещений без повышенной опасности по степени вероятности поражения электрическим током, вследствие этого к оборудованию предъявляются следующие требования: экран монитора должен находиться на расстоянии не менее 50 см от пользователя (расстояния от источника).

Для обеспечения защиты от поражения электрическим током при прикосновении к металлическим нетоковедущим частям, которые могут оказаться под напряжением в результате повреждения изоляции, применяют следующие способы (СКЗ): защитное заземление, зануление, систему

защитных проводов, защитное отключение, изоляцию нетоковедущих частей, электрическое разделение сети, малое напряжение, компенсацию токов замыкания на землю.

Перед началом работы следует убедиться в отсутствии свешивающихся со стола или висящих под столом проводов электропитания, в целостности вилки и провода электропитания, в отсутствии видимых повреждений аппаратуры и рабочей мебели.

Помещение, в котором производилась данная работа, принадлежит к первой категории, т.е. к помещениям без повышенной опасности по степени вероятности поражения электрическим током с номинальным напряжением до 1 000 В. Значения тока, напряжения и сопротивления заземления в помещении не превышают предельно допустимые, определённые в ГОСТ 12.1.038-82 [1]: 0,1 мА, 36 В и 4 Ом соответственно.

5.3.6 Психофизиологические факторы

Значительное умственное напряжение и другие нагрузки приводят к переутомлению функционального состояния центральной нервной системы, нервно-мышечного аппарата рук. Нерациональное расположение элементов рабочего места вызывает необходимость поддержания вынужденной рабочей позы. Длительный дискомфорт вызывает повышенное позвоночное напряжение мышц и обуславливает развитие общего утомления и снижение работоспособности.

При длительной работе за экраном дисплея появляется выраженное напряжение зрительного аппарата, головные боли, усталость и болезненное ощущение в глазах, в пояснице, в области шеи, руках.

Режим труда и отдыха работника: при вводе данных, редактировании программ, чтении информации с экрана непрерывная продолжительность работы не должна превышать 4-х часов при 8-часовом рабочем дне. Через каждый час работы необходимо делать перерыв на 5-10 минут, а через два часа на 15 минут.

С целью снижения или устранения нервно-психологического,

зрительного и мышечного напряжения, необходимо проводить комплекс физических упражнений и сеансы психофизической разгрузки и снятия усталости во время регламентируемых перерывов, и после окончания рабочего дня.

5.4 Экологическая безопасность

С точки зрения использования ресурсов компьютер потребляет сравнительно небольшое количество электроэнергии, что положительным образом сказывается на общей экономии потребления электроэнергии в целом. При написании данной работы вредных выбросов в атмосферу, почву и водные источники не производилось, радиационного заражения не произошло, чрезвычайные ситуации не наблюдались, поэтому ущерба окружающей среде не было нанесено.

Основными отходами являются черновики бумаги, отработавшие люминесцентные лампы и картриджи. С целью утилизации отходов исследования бумага сдавалась в пункт приёма макулатуры ООО «Чистый мир», использованные лампы отправлялись в ООО НПП «Эко-том», а отработавшие картриджи — в ООО «ЭкоКартридж».

Компания ООО «Чистый мир» принимает на переработку макулатуру (картон, офисная бумага, книги, газеты), пластик (PETE, PE-HD, PE-LD, PP, PS), пленки стрейч, пленки ПВД, ПНД и стеклотару. Основным видом деятельности компании ООО НПП «Эко-том» является сбор и утилизация отходов, в том числе и люминесцентных ламп. А компания ООО «ЭкоКартридж» занимается утилизацией картриджей для принтеров.

5.5 Безопасность в чрезвычайных ситуациях

Чрезвычайная ситуация (ЧС) — обстановка на определенной территории, сложившаяся в результате аварии, опасного природного явления, катастрофы, стихийного или иного бедствия, которая может повлечь или повлекла за собой человеческие жертвы, ущерб здоровью людей или окружающей среде, значительные материальные потери и нарушение условий жизнедеятельности людей.

Наиболее типичные для нашего региона вида ЧС, возможных на предприятии: пожар, сильный мороз, несанкционированное проникновение посторонних лиц. Меры по предупреждению ЧС, возникших вследствие морозов:

1. Повышение устойчивости системы электроснабжения. В первую очередь целесообразно заменить воздушные линии электропередач на кабельные (подземные) сети, использовать резервные сети для потребителей, предусмотреть автономные резервные источники электропитания объекта (передвижные электрогенераторы).

2. Обеспечение устойчивости теплоснабжения за счет запасных автономных источников теплоснабжения, кольцевания системы, заглубления теплотрасс.

3. Обеспечение устойчивости систем водоснабжения (устройство дублирования вод питания, кольцевание системы, заглубление водопроводов, обустройство резервных емкостей и водохранилищ, очистка воды от вредных веществ и т.п.).

4. Обеспечение устойчивости системы водоотведения. Повышение устойчивости системы канализации достигается созданием резервной сети труб, по которым может отводиться загрязненная вода при аварии основной сети. Должна быть разработана схема аварийного выпуска сточных вод непосредственно в водоемы. Насосы, используемые для перекачки загрязненной воды, комплектуются надежными источниками электропитания.

Для предупреждения ЧС, связанных с несанкционированным проникновением посторонних лиц, необходимы следующие меры безопасности:

1. Организовать контрольно-пропускной пункт.
2. Установить системы видеонаблюдения во всех помещениях здания, а также на всех входах и выходах.

3. Установить оповещающие системы безопасности при несанкционированном проникновении на предприятие в нерабочее время.

При возникновении чрезвычайной ситуации необходимо:

1. Сообщить руководству (дежурному).
2. Позвонить в соответствующую аварийную службу или МЧС — тел. 112.
3. Принять меры по ликвидации аварии в соответствии с инструкцией.

5.6 Выводы по разделу

Проанализировав условия труда на рабочем месте, где была разработана магистерская работа, можно сделать вывод, что помещение удовлетворяет необходимым нормам и в случае соблюдения техники безопасности и правил пользования компьютером работа в данном помещении не приведет к ухудшению здоровья работника.

Само помещение и рабочее место в нем удовлетворяет всем нормативным требованиям. Кроме того, действие вредных и опасных факторов сведено к минимуму, т.е. микроклимат, освещение и электробезопасность соответствуют требованиям, предъявленным в соответствующих нормативных документах.

Относительно рассмотренного вопроса об экологической безопасности можно сказать, что деятельность помещения не представляет опасности окружающей среде.

Важно добавить, что монитор компьютера служит источником ЭМП - вредного фактора, который отрицательно влияет на здоровье работника при продолжительной непрерывной работе и приводит к снижению работоспособности. Поэтому во избежание негативного влияния на здоровье необходимо делать перерывы при работе с ЭВМ и проводить специализированные комплексы упражнений для глаз.

5.7 Перечень научно-технической документации

1. ГОСТ 12.1.038-82 ССБТ. Электробезопасность. Предельно допустимые уровни напряжений прикосновения и токов.
6. СанПиН 2.2.2/2.4.1340–03. Санитарно-эпидемиологические правила и нормативы «Гигиенические требования к персональным электронно-вычислительным машинам и организации работы».
7. ГОСТ 12.2.032-78 ССБТ. Рабочее место при выполнении работ сидя. Общие эргономические требования.
8. ГОСТ 12.0.003-2015 ССБТ. Опасные и вредные производственные факторы. Классификация.
9. СанПиН 2.2.4.548–96. Гигиенические требования к микроклимату производственных помещений.
10. СП 52.13330.2016 Естественное и искусственное освещение. Актуализированная редакция СНиП 23-05-95*
11. ГОСТ 12.1.003-2014 ССБТ. Шум. Общие требования безопасности.
12. СН 2.2.4/2.1.8.562–96. Шум на рабочих местах, в помещениях жилых, общественных зданий и на территории застройки.
13. ГОСТ 12.1.006-84 ССБТ. Электромагнитные поля радиочастот. Общие требования безопасности.
14. ГОСТ 12.1.029-80 ССБТ. Средства и методы защиты от шума. Классификация.
15. ГОСТ Р 22.0.01-2016. Безопасность в ЧС. Основные положения.

Заключение

В ходе проведения научно-технического исследования были получены следующие научные и практические результаты:

1. Проанализованы существующие нейросетевые методы, используемые для прогнозирования финансовых временных рядов. На основании полученной информации выбран оптимальный тип нейронной сети – многослойный персептрон MLP (метод обучения BFGS);

2. Для проведения исследования исходные данные были качественно подготовлены, так как все числовые значения должны быть преобразованы в определённый диапазон, подходящий для сети.

3. Построен прогноз цен закрытия акций компании «Сбербанк» (SBER) для задачи регрессии при помощи нейронных сетей: MLP 20-4-1 (логистическая функция активации) и MLP 6-3-1 (гиперболическая функция активации). Также при помощи MLP 20-8-2 (логистическая функция активации) построен прогноз цен закрытия акций компаний «Сбербанк» (SBER) для задачи двухзначной классификации (Рост/Спад).

4. Для задачи регрессии установлено, что если обучать сети одним и тем же алгоритмом, то в большинстве случаев ошибка прогноза на тестовой выборке SBER колеблется около одного значения – 0,7%, при этом на точность прогноза не влияет ни количество скрытых нейронов, ни количество нейронов, подаваемых на вход. Этот факт свидетельствует о том, что сети с рассмотренной архитектурой являются малопригодными для регрессионных задач.

5. Для задачи двухзначной классификации «Рост/Спад» установлено, что большинство построенных сетей имеют процент правильной классификации около 60% и выше, это говорит о том, что сети с данной архитектурой можно использовать для решения задачи классификации.

6. Для задачи трехзначной классификации «Рост/Спад/Нейтрально» установлено, что у всех построенных сетей процент правильной классификации чуть больше 50%. Полученный результат нельзя признать

положительным, так как данный способ принятия решения ничем не отличается от подбрасывания монетки.

На основании нашего исследования мы можем сделать вывод, что для задач регрессии и трехзначной классификации «Рост/Спад/Нейтрально» сети с рассмотренной архитектурой оказались малопригодными. Что касается задачи двухзначной классификации «Рост/Спад», то в этом случае процент правильной классификации составляет больше 60 % для всех построенных сетей. Данные результаты можно признать положительными, а построенную сеть MLP 20-8-2 использовать для прогнозирования направления движения цены.

Список публикаций студента

1. Булыкина А. А. «Статистический анализ производственных показателей предприятий различных форм собственности» // Перспективы развития фундаментальных наук: сборник трудов XIV Международной конференции студентов, аспирантов и молодых ученых, Томск, 25-28 апреля 2017 г., Томск: ТПУ, 2017 - Т. 3. Математика - с. 26-29, 1 уч. — Свободный доступ из сети Интернет. Режим доступа: http://science-persp.tpu.ru/Arch/Proceedings_2017_vol_3.pdf

2. Булыкина А.А., Михальчук А.А., Спицын В.В. «Рентабельность предприятий автомобильной промышленности России в разрезе форм собственности за период 2012-2016 гг.» // Информационные технологии в науке, управлении, социальной сфере и медицине: сборник научных трудов IV Международной научной конференции, 5-8 декабря 2017 г., Томск — [с. 387-391]. — Свободный доступ из сети Интернет. Режим доступа: https://portal.tpu.ru/appnews/files/18083/ik_cbornik.pdf

3. Булыкина А.А., Гуменников И.В., Михальчук А.А., Спицын В.В. «Анализ неустойчивости показателей предприятий по производству транспортных средств» // Информационные технологии в науке, управлении, социальной сфере и медицине: сборник научных трудов IV Международной научной конференции, 5-8 декабря 2017 г., Томск, в 2 ч. / ТПУ — 2017. — Ч. 1. — [с. 391-396]. — Свободный доступ из сети Интернет. Режим доступа: https://portal.tpu.ru/appnews/files/18083/ik_cbornik.pdf

4. Булыкина А.А., Мехеда А.А., Михальчук А.А., Спицына Л.Ю., Спицын В.В. «Динамика показателей предприятий машиностроения России в разрезе форм собственности: дисперсионный анализ» // Информационные технологии в науке, управлении, социальной сфере и медицине: сборник научных трудов IV Международной научной конференции, 5-8 декабря 2017 г., Томск — [с. 381-386]. — Свободный доступ из сети Интернет. Режим доступа: https://portal.tpu.ru/appnews/files/18083/ik_cbornik.pdf

5. Булыкина А.А., Гуменников И.В., Михальчук А.А., Спицын В.В.

«Планирование себестоимости для предприятий машиностроения в иностранной собственности» // VIII международный молодёжный форум «Новые форматы транснациональной научно-образовательной деятельности» 26-27 апреля 2018 года, г. Томск. — [с. 83-86]. — Свободный доступ из сети Интернет. Режим доступа: https://sci-school.tspu.edu.ru/wp-content/uploads/2019/publications/public_forum_2018.pdf

6. Булыкина А.А., Михальчук А.А., Спицын В.В. «Рентабельность предприятий химической промышленности России в разрезе форм собственности» // VIII международный молодёжный форум «Новые форматы транснациональной научно-образовательной деятельности» 26-27 апреля 2018 года, г. Томск. — [с. 80-83]. — Свободный доступ из сети Интернет. Режим доступа: https://sci-school.tspu.edu.ru/wp-content/uploads/2019/publications/public_forum_2018.pdf

7. Булыкина А.А., Михальчук А.А., Спицын В.В. «Кластерный анализ динамики выручки предприятий в иностранной собственности по Производству электроники и электрооборудования» // Научная сессия ТУСУР – 2018: сборник научных трудов XXIII Международной научно-технической конференция студентов, аспирантов и молодых ученых, г. Томск, 16 – 18 мая 2018 г. — [С. 21-23]. — Свободный доступ из сети Интернет. Режим доступа: https://storage.tusur.ru/files/115520/2018_5.pdf

8. Булыкина А.А., Михальчук А.А., Спицын В.В. Рыжкова М.В., Трифонов А.Ю., «Техническая эффективность металлургических предприятий в российской и иностранной собственности в 2012-2016 гг.» // Вестник Том. гос. ун-та. Экономика. 2018. № 44. DOI: 10.17223/19988648/44/19 — [С. 283-304]. Свободный доступ из сети Интернет. Режим доступа: http://journals.tsu.ru/economy/&journal_page=archive&id=1798&article_id=3963

6

9. Булыкина А.А., Михальчук А.А., Спицын В.В. «Оценка эффективности предприятий химической промышленности России в разрезе

форм собственности: DEA подход и индекс Малмквиста» // Информационные технологии в науке, управлении, социальной сфере и медицине: сборник научных трудов V Международной научной конференции, в 2 частях. Под редакцией О. Г. Берестнева [и др.], Томск, 17-21 декабря 2018 гг. — [С. 12-18]. — Свободный доступ из сети Интернет. Режим доступа: https://portal.tpu.ru/files/departments/publish/Sbornik_InfTehno1_P2.pdf

10. Булыкина А.А. «Рентабельность высокотехнологичных отраслей промышленности и услуг России: анализ данных за 2013–2017 гг.» // Научная сессия ТУСУР–2019: сборник научных трудов XXIV Международная научно-техническая конференция студентов, аспирантов и молодых ученых, 22–24 мая 2019 г., Томск — [С. 151-154]. — Свободный доступ из сети Интернет. Режим доступа: https://storage.tusur.ru/files/127276/rinc2019_2.pdf

11. Булыкина А.А., Михальчук А.А., Спицын В.В. «Динамика показателей промышленных предприятий России в разрезе форм собственности в условиях кризиса» // Научная сессия ТУСУР–2019: сборник научных трудов XXIV Международная научно-техническая конференция студентов, аспирантов и молодых ученых, 22–24 мая 2019 г., Томск — [с. 168-172]. — Свободный доступ из сети Интернет. Режим доступа: https://storage.tusur.ru/files/127276/rinc2019_2.pdf

12. Булыкина А.А., Михальчук А.А., Спицын В.В., Трифонов А.Ю. «Развитие высокотехнологичных отраслей промышленности и услуг России в условиях кризиса: анализ панельных данных за 2013-2017 гг.» // Журнал «Экономический анализ: теория и практика» т. 18, вып. 8, август 2019, — [с. 1394–1411]. — Свободный доступ из сети Интернет. Режим доступа: <https://www.fin-izdat.ru/journal/analiz/detail.php?ID=74849>

13. Булыкина А.А., Михальчук А.А., Спицына Л.Ю., Трифонов А.Ю., «Кластеризация регионов России по финансовым показателям предприятий в иностранной и совместной собственности» // Информационные технологии в науке, управлении, социальной сфере и медицине: сборник научных трудов VI Международной конференции, 14-19 октября 2019 г., Томск / ТПУ; ред. О. Г.

Берестнева [и др.] — Томск: Изд-во ТПУ, 2019. — [288-292]. — Свободный доступ из сети Интернет. Режим доступа: https://portal.tpu.ru/files/departments/publish/Sbornik_ISHITR_InfTehno1.pdf

14. Булыкина А.А., Михальчук А.А., Спицын В.В., «Динамика финансовых показателей предприятий нефтегазовой промышленности России в условиях кризиса: дисперсионный анализ в разрезе форм собственности»// Информационные технологии в науке, управлении, социальной сфере и медицине: сборник научных трудов VI Международной конференции, 14-19 октября 2019 г., Томск/ ТПУ; ред. О. Г. Берестнева [и др.]. — Томск: Изд-во ТПУ, 2019. — [219-222]. — Свободный доступ из сети Интернет. Режим доступа: https://portal.tpu.ru/files/departments/publish/Sbornik_ISHITR_InfTehno1.pdf

15. Булыкина А.А., Михальчук А.А., Спицын В.В., Новосельцева Д.А., «Эффективность деятельности новых предприятий сектора ИТ в России: кластерный анализ на основе нейросетей» // Научная сессия ТУСУР–2020: сборник научных трудов XXV Международная научно-техническая конференция студентов, аспирантов и молодых ученых, 25 – 27 мая 2020 г., Томск — [с. 168-172]. — Свободный доступ из сети Интернет. Режим доступа: https://storage.tusur.ru/files/127276/rinc2019_2.pdf

16. Булыкина А.А., Михальчук А.А., Спицын В.В., Хижняк А.В., «Развитие высокотехнологичных отраслей промышленности и услуг России: анализ панельных данных за 2017-2018 гг.» // Научная сессия ТУСУР–2020: сборник научных трудов XXV Международная научно-техническая конференция студентов, аспирантов и молодых ученых, 25 – 27 мая 2020 г., Томск — [с. 168-172]. — Свободный доступ из сети Интернет. Режим доступа: https://storage.tusur.ru/files/127276/rinc2019_2.pdf

Список используемых источников

1. Шарп У.Ф., Александер Г., Бэйли Дж.В. Инвестиции. – М.:Инфра М, 1998. – 1028 с.
2. Ежов А.А., Шумский С.А. Нейрокомпьютинг и его применения в экономике и бизнесе. – М.: МИФИ, 1998. – 222 с.
3. Панфилов П.Н. Введение в нейронные сети // Современный трейдинг. – 2001. – № 2. – С. 12–17.
4. Прогнозирование динамики цен на фондовом рынке / Мицель А.А., Ефремова Е. А. // Известия Томского политехнического университета, 2006. – Т. 309. - № 8. – С. 197-201. Режим доступа: <https://elibrary.ru/item.asp?id=9459148>
5. Хайкин, С. Нейронные сети: полный курс, 2-е изд., испр.: Пер. с англ.– Рязань, 2003. – 140 с.
6. Комашинский , В.И. Нейронные сети и их применение в системах управления и связи./ В.И. Комашинский , Д.А Смирнов.– М:Горячая линия Телеком 2003. – 94с.
7. Бэстенс, Д.-Э. Нейронные сети и финансовые рынки. Принятие решений в торговых операциях/ Д.-Э. Бэстенс, В.-М. Ван Ден Берг, Д. Вуд . – М.: ТВП, 1997. – 236с.
8. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей. А.Н. Горбань. Сибирский журнал вычислительной математики, 1998. Т.1, №1, с.12-24.
9. Уоссермен Ф. Нейрокомпьютерная техника. М.: Мир, 1992. 240 с.
10. Нейронные сети. [Электронный ресурс] Режим доступа: <http://www.zadachi.ru/zip/ctatictika.zip>
11. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.
12. Хайкин С. Нейронные сети. Полный курс. М.: Издательский дом Вильямс, 2006. 1104 с.
13. R. Rojas. Neural Networks. Springer-Verlag, 1996.

14. Bernard Widrow and Michael A. Lehr. Artificial neural networks of the perceptron and backpropagation family. Stanford University, CA 94305-4055.
15. G. Cybenko. Approximation by superpositions of sigmoidal functions. Mathematics of Control, Signals and Systems, 1989.
16. Каллан Р. Основные концепции нейронных сетей. М.: Издательский дом Вильямс, 2003.- 288 с.
17. Gallant. Perceptron based learning algorithms. IEEE Transactions on Neural Networks, 1990.
18. Kur Horvik. Multilayer feedforward networks are universal approximators. University of California, 1989.
19. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. М.: Горячая линия - Телеком, 2002. 382 с.
20. Нейронные сети. Statistica Neural Networks: Пер. с англ.. М.: Горячая линия - Телеком, 2000. - 182 с.
21. Kevin Gurney, An introduction to neural networks, University of Sheffield, UCL Press, 1997.
22. Головкин В.А. Нейроинтеллект: теория и применения. Книга 1. Организация и обучение нейронных сетей с прямыми и обратными связями. 1999.
23. J. Minsky, S. Papert. Perceptions: An Introduction to Computational Geometry. MA. MIT Press, Cambridge, 1969
24. Розенблатт Ф. Принципы нейродинамики. Перцептроны и теория механизмов мозга. – М.: Мир, 1965. – 302 с.
25. Горбань А.Н. Обучение нейронных сетей. – М.: СП «Параграф», 1990 – 160 с.
26. Боровиков, В.П. Нейронные сети. Statistica Neural Networks. Методология и технологии современного анализа данных / В.П. Боровиков. – 2-е изд. – М.: Горячая линия – Телеком, 2008. – 392 с.

Приложение А

Программный код авторегрессионной модели в математическом пакете

Wolfram Mathematica:

```
Y = Import["C:\\Sber.xls"];
Y0 = Flatten[Y, 1];
N0 = 247;
M = 227;
AR = 1;
kMax = N0 - M - AR;
Z = ConstantArray[0, kMax];
For[k = 1, k < kMax + 1, k++,
  Y1 = Y0[[k ;; k + M - 1]];
  YY = Y0[[k + AR ;; k + M + AR - 1]];
  X0 = Table[1., {M}];
  X = Transpose[{X0, Flatten[Transpose[Y1]]}];
  XT = Transpose[X];
  B = Inverse[XT.X].XT.YY;
  YP = Take[YY, -AR];
  XP = {Join[{1}, Flatten[YP]]};
  Z[[k]] = (XP.B)[[1, 1]]
Z1 = Flatten[Transpose[Y0[[M + AR + 1 ;; N0]]]];
StandardDeviation[Z - Z1]
1.977
```

В представленном программном коде:

- M – это количество точек, которое используется для модели;
- AR – порядок авторегрессии;
- Z – массив однодневных прогнозов;
- Z1 – соответствующие значения цен акций.

В качестве оценки качества была использована среднеквадратичная ошибка прогноза и средняя абсолютная ошибка.

Приложение Б

В программе STATISTICA, чтобы построить однодневные прогнозы, нужно разбить выборку следующим образом: количество значений, которое подается на вход смещается на одно значение вперед при каждом следующем шаге. Чтобы не разбивать вектор исходных значений вручную, в программе Excel был реализован макрос GetTable (диапазон данных; размер окна сдвига) для представления исходной выборки в таблицу, на основе которой будут построены однодневные прогнозы.

Программы код (макрос в Excel):

```
Public Function GetTable (inputRange As Range, windowSize As Integer) As Variant
    Dim arrayLength As Integer
    arrayLength = inputRange.Count
    Dim outputArray() As Variant
    ReDim outputArray(1 To Int(arrayLength - windowSize), 1 To windowSize)
    Dim i As Integer
    Dim j As Integer
    For i = 1 To Int(arrayLength - windowSize)
        Debug.Print Iterration1
        For j = 1 To windowSize
            outputArray(i, j) = inputRange(i + j - 1)
            Debug.Print outputArray(i, j)
        Next j
    Next i
    GetTable = outputArray
End Function
```

Приложение В

Раздел ВКР, выполненный на иностранном языке

Predicting financial time series using neural networks

Студент:

Группа	ФИО	Подпись	Дата
0BM81	Булыкина А.А.		

Руководитель ВКР:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОЭФ	Шинкеев М.Л.	к. ф.-м. н., доцент		

Консультант-лингвист отделения иностранных языков ШБИП:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Старший преподаватель ОИЯ	Смирнова У.А.	—		

Introduction

Artificial neural networks (ANNs) are widely spread among various kinds of applied tasks, such as data compression, image recognition, optimization, data analysis, control tasks, etc. One of the most important areas of practical use of ANNs is anticipating problems, specifically anticipating time series problems on the stock market, forecasting the exchange rate, calculation of electricity consumption, predicting the solvency of creditors, loads of energy systems, etc. We see that ANNs can be used for almost any kind of problem, including the absence of an explicit mathematical model or a lack of data for the effective application of statistical methods.

Prediction of the behaviour of complex dynamic systems is a non-trivial task, since the prediction of such systems is based on the identification of hidden patterns in the accumulated data. Prediction of financial time series is a typical example of such tasks. The formation of the stock exchange price includes the collective psychology of bidders, which is a certain difficulty, but there is accumulated data in the form of financial time series.

The relevance of the master's thesis consists in the use of neural networks to solve the difficultly formalized task of predicting financial time series.

In this paper, to solve the problem of predicting financial time series, neural network methods are considered, which differ from other models in their ability to establish non-linear relationships between future and actual values and good scalability.

The main goal of this work is the estimation of closing prices for shares of leading Russian companies (Sberbank) using the selected neural network model. A neural network should be optimal in terms of internal structure, a way to control information flows between neurons. The selected neural network model will be used to solve a practical problem.

The object of this study is the closing prices of shares of leading Russian companies (Sberbank).

The subject of the study are neural network models for predicting financial time series.

To achieve this goal, the following tasks were set and solved:

1. To study the main types of information models of artificial neural networks used to predict financial time series;
2. To choose the optimal information model of a neural network to solve an existing applied task;
3. To prepare data for building a prediction at high quality standards;
4. To give a forecast of closing prices for shares of leading Russian companies (Sberbank) for the tasks of regression and two-digit classification using neural networks of various structures;
5. To draw a conclusion about the possibility of using neural networks of the architecture in question to predict financial time series.

Fundamental and technical analysis of the security market

One of the most important tasks of investing is an attempt to find such financial instruments applying which you can increase or at least keep your investments. Large investors, medium-sized players and small speculators try to foresee the future and predict the future dynamics of the markets in various ways.

For the analysis of stock markets, there is a huge number of mathematical methods [1-3], among which the most popular were fundamental and technical analysis.

Fundamental analysis is a direction in the security analysis that seeks to determine their true values based on a study of the economic factors associated with them. True values are compared with current prices in order to determine deviation rate. However, fundamental analysis is often not enough to determine the exact moment of transaction completed. In this area, technical analysis is applied.

Technical analysis assumes that all objective data about the issuing company (stock of raw materials, expected dividends, economic condition, etc.) are already included in the current share price. Therefore, it is believed that the dynamics of the share market value is not a direct reaction to events, but depends only on the

assessment of events by market participants [4].

Both methods compete each other and are equally indicators of market conditions.

Technical analysis is a generally accepted approach to market research, the purpose of which is forecasting. Technical analysis assumes that the market has a memory. This means that the laws of its past behaviour significantly influence the future rate dynamics. In other words, the market can “remember” how to behave in a certain situation, the next time it can happen again.

In the last decade, there has been a steady increase in the appeal of technical analysis of various indicators of market behaviour based on a set of empiric rules (or rules of thumb). Technical analysis focuses on the individual behaviour of a given financial instrument, outside of its relationship with other securities. However, technical analysis is very subjective and does not work well on the right edge of the chart - exactly where you need to predict the direction of the price. Therefore, neural network analysis is becoming increasingly popular, because unlike the technical analysis, it does not suppose any restrictions on the nature of the input information. This can be either indicators of a given time series or information about the behaviour of other market instruments. It is not without reason that neural networks are used by institutional investors (for example, large pension funds) working with large portfolios that are especially important for correlations between different markets [4].

Neural network modelling in its pure form is based only on data, without involving any a priori considerations. This is its strength and at the same time its Achilles' heel. The available data may not be enough for training; the dimension of potential inputs may be too large.

Therefore, for a good forecast, one needs to use, firstly very well prepared data, and secondly neural packages with great functionality.

Introduction to Neural Network Theory

A neural network is a parallel-distributed information processing structure consisting of neurons that are interconnected by links.

Neural networks is a powerful modelling method that allows you to reproduce complex nonlinear dependencies. The abilities to simulate non-linear processes, work with noisy data and adaptability make it possible to use neural networks to solve a wide class of economic problems.

The most important feature of a neural network, which testifies to its wide capabilities and huge potential, is parallel processing of information by all links, which can significantly speed up the information processing. In addition, with a large number of interneuron connections, the network becomes resistant to errors that occur on some lines.

Another equally important quality is an ability to learn and generalize accumulated knowledge. A neural network has the features of artificial intelligence. A network trained on a limited set of data is able to generalize the obtained information and show good results on data that was not used in its training [4].

Network structure

A neuron is a unit of information processing in a neural network. The general model of a neuron is as follows: a neuron has several channels of information input called dendrites and a channel of information output called an axon.

The axon of the neuron is connected to the dendrites of other neurons via synapses. When firing, a neuron sends a signal along its axon. Through the synapses, the signal is transmitted to other neurons, which in turn can be firing or go into inhibition state. A neuron is firing, if the total level of signals arriving at it exceeds a certain level — the threshold of excitation or activation.

Figure 1 presents a model of the neuron underlying artificial neural networks [5].

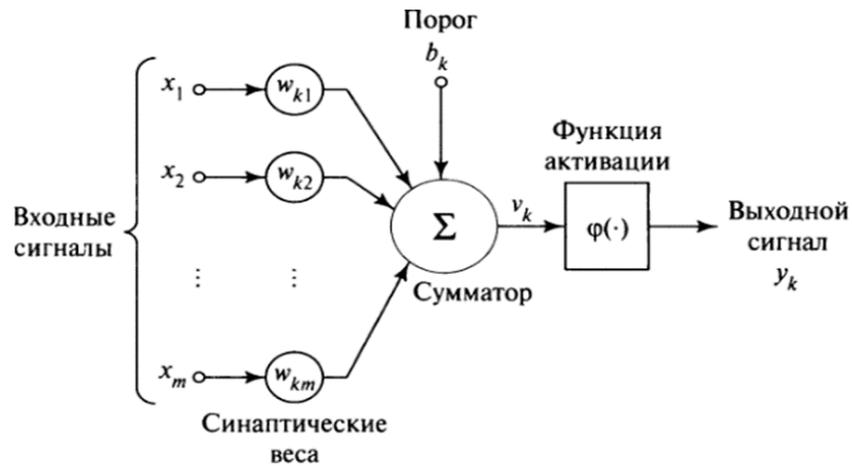


Figure 1 - Model of a neuron

The figure shows that the input of the neuron receives signals x_i through the connection, which has a certain strength and weight w_{ki} . The coefficients w_{ki} are called weights of synaptic connections, a positive value of which corresponds to firing synapses, a negative value corresponds to inhibitory synapses. If $w_{ki} = 0$, then they say that there is no connection between the neuron k and the neuron i . Next, the signals are converted in the adder and a threshold b_k is added, and the result is converted using the function φ and sent to the output of the neuron. In a mathematical representation, the functioning of a neuron k can be described with the following pair of equations:

$$v_k = \sum_{i=1}^m w_{ki} x_i$$

w_{ki} are the synaptic weights of the neuron k ;

x_i – input signals;

$$y_k = \varphi(v_k + b_k)$$

φ is the activation function;

v_k – linear combination of input actions;

b_k – activation threshold.

The signal received by neurons is converted using a nonlinear activation function φ in the output signal $y_k = \varphi(v_k)$.

Activation function φ is a non-linear function that simulates the process of

transmission of firing.

Several activation functions are used: unit step function, sigmoid function, piecewise linear function, sign function. For forecasting is often used a nonlinear activation function with saturation, the so-called logistic function or sigmoidal.

$$\varphi(v) = \frac{1}{1 + e^{-av}}$$

a is the slope parameter of the sigmoid function;

v – linear combination of input action.

Changing the parameter a , you can build functions with different steepness. A sigmoid function can take an infinite number of values in the range from 0 to 1, as shown in Figure 2 [12].

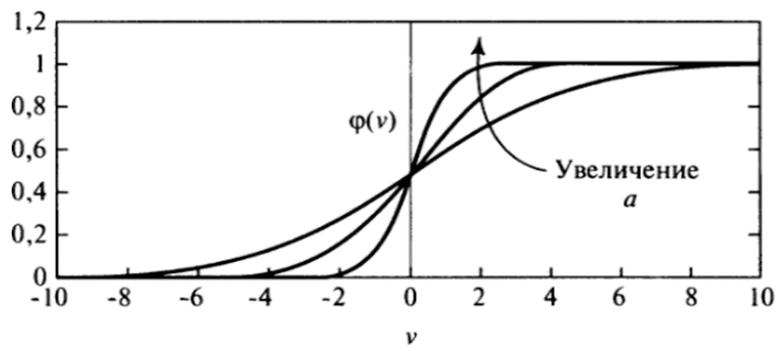


Figure 2 is a graph of a sigmoid function.

An artificial neural network is built of neurons connected to each other. The organization of neurons and their connections into a specific structure (architecture) has a significant impact on the computing capabilities of a neural network. Three main types of neural networks can be distinguished: fully connected networks (Fig. 3-a), multilayer networks (Fig. 3-b), weakly connected networks (neural networks with local connections) (Fig. 3-c).

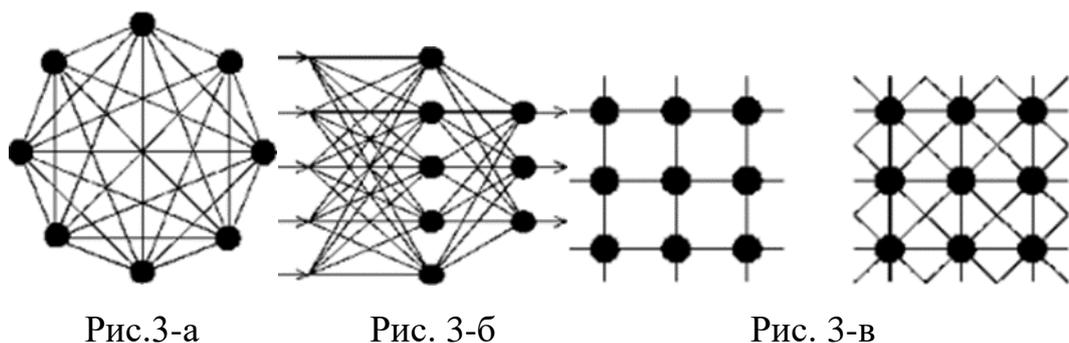


Рис.3-а

Рис. 3-б

Рис. 3-в

Topologies of Neural Networks

Network topologies can be divided into two main groups: direct distribution networks and recurrent networks.

1. Direct distribution networks.

In a multilayer neural network, neurons are arranged in layers. The neurons of the first layer receive signals, convert them and transmit to the neurons of the second layer, then the second layer is triggered, etc. to the k-th layer, which produces output signals. Such a network is called a direct distribution multilayer network. The intermediate layers between the external input signal and the output layer are called hidden, Figure 4. If all nodes of each layer are connected to all nodes of adjacent layers, then such a network is called fully connected. If some of the synaptic connections are absent, then the network is called incomplete.

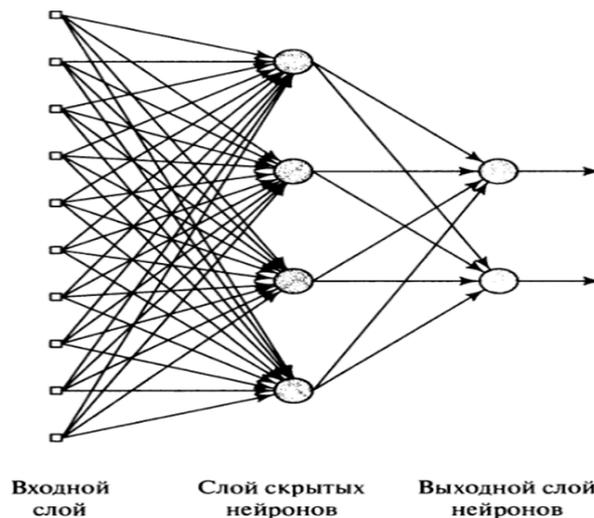


Figure 4 - A fully connected multilayer network of direct distribution with one hidden layer

Direct-connected networks can serve as a universal means for approximation, but there is no rule to find the optimal network topology for a given problem.

2. Recurrent networks.

Recursive networks differ from direct distribution networks by the presence of at least one feedback. The presence of feedbacks in networks has a direct impact on their learning ability and their performance [5]. Such networks are of great interest to researchers in the field of neural networks. However, in solving practical

problems direct distribution networks turned out to be most useful.

The choice of the structure (topology) of the neural network is carried out in accordance with the features and complexity of the task.

Figure 5 shows the most common neural network architectures [6].

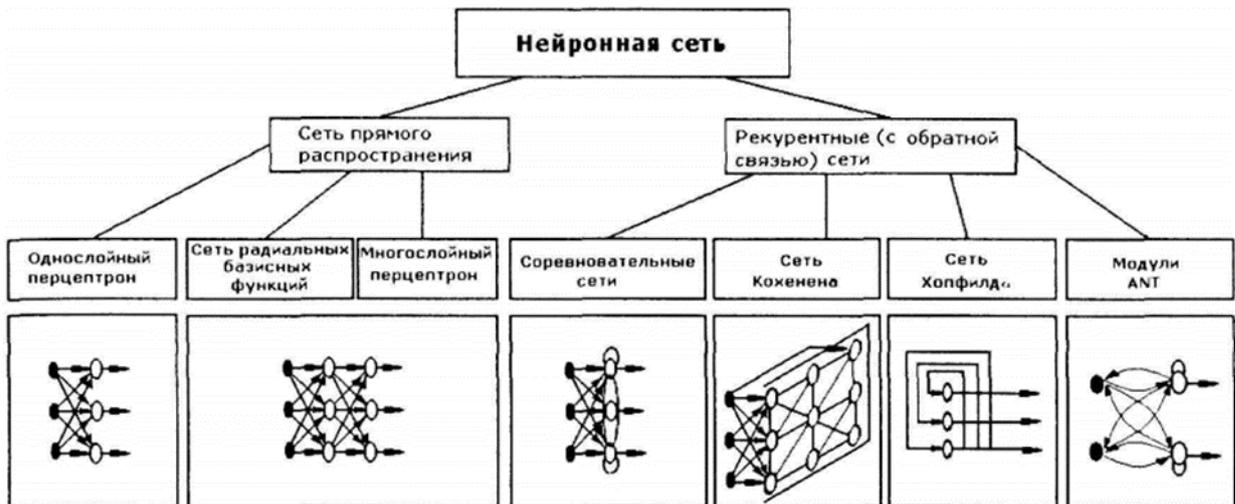


Figure 5 - Neural network architectures

Question: can any function be represented using neural networks?

Theorem. (Kolmogorov, 1957). Any continuous function of n arguments on a unit cube $[0,1]^n$ can be represented as a superposition of continuous functions of one argument and the “+” operation:

$$f(x^1, x^2, \dots, x^n) = \sum_{k=1}^{2n+1} h_k \left(\sum_{i=1}^n \varphi_{ik}(x^i) \right)$$

Функция активации скрытого нейрона (points to h_k)
 Скрытый слой нейронов (points to the inner sum)
 Входной слой нейронов (points to x^i)
 Функции синаптической связи (points to φ_{ik})
 Двухслойная нейронная сеть описывает почти любую функцию (points to the entire equation)

Neural network training

Network training is the adjustment of its internal parameters in order to adapt to external influences to solve a specific problem.

The process of training a neural network is iterative, and its steps are called *epochs* or *cycles*. At each training cycle, synaptic coefficients w_{ki} are calculated

based on examples grouped into training sets (training samples). Such a set consists of data with the value indicated for each of items of the output parameter, that it is desirable to obtain. The action that occurs in this case can be called controlled learning: the teacher enters a vector of input data to the network input, and reports the desired result value to the output node. Controlled training of a neural network can be considered as a solution to an optimization problem. The difference between the correct solution and the response is an error that should be reduced by setting free parameters. By adjusting the network in order to minimize the error we cannot be sure that it is possible to achieve an even smaller error [7].

The error surface has a complex structure and has a number of unpleasant properties; in particular, it can have local minima, flat regions, saddle points, and long narrow ravines. It is impossible to determine the position of the global minimum on the surface of errors by analytical properties, so training a neural network essentially consists in studying this surface. Achieving a global minimum is called the convergence of the learning process. More than a hundred training algorithms have been developed, algorithms differ from each other in optimization strategies and error criteria. The root-mean-square error E , which is defined as the sum of the squares between the desired output value and the y_k values actually obtained on the network, is usually taken as a measure of an error:

$$E = \frac{1}{P} \sum_{k=1}^p (d_k - y_k)^2$$

P is the number of examples in the training set;

d_k – the desired output value;

y_k – values received on the network.

The most common direct-link learning neural network learning algorithm is a backpropagation algorithm. This method is based on the calculation of the error surface gradient vector, which indicates the direction of the shortest descent along the surface from a given point. The sequence of steps minimizes surface errors after a series of iterations. The obvious difficulty here is the choice of step length. With a bigger length convergence is faster, but there is a danger of “jumping over” the

solution, especially in cases where the response surface has the shape of a narrow ravine. With a small step, the direction of advancement is chosen correctly, but many iterations are required to achieve a minimum. In practice, the step size is taken proportional to the steepness of the slope with a certain constant, called the speed of learning.

The error backpropagation algorithm is a gradient descent algorithm that minimizes the squared error E :

$$E = \frac{1}{2} \sum_{k=1}^p \sum_i (d_k^i - y_k^i)^2$$

The index i runs through all the exits of a multilayer network.

At each epoch, all training observations are fed to the network input in turn, the network output values are compared with the target values, and an error is calculated. The error value, as well as the surface gradient of the errors, are used to adjust the weights, after that step all actions are repeated. The learning process stops when either a certain number of epochs is passed, or the error has reached a certain level, or completely stops decreasing.

The danger of the method lies in the fact that in this way we minimize the error on the training set, and this is not the same as minimizing "real" error on the surface of errors. Most of all, this difference affects the problem of retraining, or overfitting.

There are two training modes:

❖ Serial (above there is an example)

- Learning objects pass through the network one at a time
- Weights are adjusted for each object

❖ Batch

- Weights are adjusted only after passing through the network of the entire

training set:

$$\Delta w_{ji}(n) = -\eta \frac{\partial E_{av}}{\partial w_{ji}} = -\eta \sum_{n=1}^N e_j(n) \frac{\partial e_j(n)}{\partial w_{ji}}$$

In our case, *the Quasi-Newton (BFGS) learning algorithm was used* to train the network.

Training mode: Batch. In Newton's algorithm the main idea is to expand the cost function up to the 2nd order at a point \mathbf{w}_n :

$$\Delta E(\mathbf{w}(n)) = E(\mathbf{w}(n+1)) - E(\mathbf{w}(n)) = g^T(n)\Delta\mathbf{w}(n) + \frac{1}{2}\Delta\mathbf{w}^T(n)H(n)\Delta\mathbf{w}(n)$$

$H(n)$ is the Hessian matrix.

- From the necessary optimality condition:

$$g(n) + H(n)\Delta\mathbf{w}(n) = 0$$

- Newton's algorithm:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \Delta\mathbf{w}(n) = \mathbf{w}(n) - H^{-1}(n)g(n)$$

However, the Hessian matrix is difficult to calculate, an iterative approximation to the inverse Hessian matrix is constructed using the BFGS algorithm (Bruden-Fletcher-Goldfarb-Shanno). This is the quasi-Newton iterative algorithm.

In the BFGS algorithm, we will solve the problem of optimizing the functional:

$$\min_{x \in R^n} f(x)$$

the function $f: R^n \rightarrow R$ is fairly smooth..

Second-order methods solve this problem iteratively, by expanding the function into a polynome of the second degree:

$$f(x_k + p) = f(x_k) + \nabla f^T(x_k)p + \frac{1}{2}p^T H(x_k)p,$$

where H is the Hessian of the functional f at the point x . The determinant of a matrix $H(f)$ is called the Hessian determinant, or simply Hessian:

$$H(f) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} & \cdots & \frac{\partial^2 f}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \frac{\partial^2 f}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$$

Calculation of the Hessian is often time-consuming, therefore, instead of the real value $H(x)$ the BFGS algorithm calculates the approximate value B_k , after which it finds the minimum of the obtained quadratic problem: $p_k = -B_k^{-1}\nabla f(x_k)$.

As a rule, after this a search is carried out along this direction for the point a_k , for which the Wolfe conditions are satisfied:

$$\begin{aligned} f(x_k - a_k p_k) &\leq f(x_k) + c_1 a_k \nabla f_k^T p_k, \\ \nabla f(x_k - a_k p_k)^T p_k &\geq c_2 \nabla f_k^T p_k, \end{aligned}$$

Constants are selected as follows: $0 < c_1 < c_2 < 1$.

As the initial approximation of the Hessian, one can take any non-degenerate well-conditioned matrix. Often the identity matrix is taken. The approximate value of the Hessian in the next step is calculated by the formula:

$$B_{k+1} = B_k - \frac{B_k s_k s_k^T B_k}{s_k^T B_k s_k} + \frac{y_k y_k^T}{y_k^T s_k},$$

I is the identity matrix, $s_k := x_{k+1} - x_k$ — the step of the algorithm at the iteration, $y_k := \nabla f(x_{k+1}) - \nabla f(x_k)$ — the change in the gradient at the iteration.

Since computing the inverse matrix is computationally difficult, instead of computing B_k^{-1} , the inverse to B_k matrix is updated $H_k = B_k^{-1}$:

$$H_{k+1} = (I - p_k s_k y_k^T) H_k (I - p_k y_k s_k^T) + p_k s_k s_k^T,$$

where $p_k = \frac{1}{y_k^T s_k}$.