

Министерство образования и науки Российской Федерации  
«Южно-Уральский государственный университет  
(национальный исследовательский университет)»

Высшая школа электроники и компьютерных наук  
Кафедра «Инфокоммуникационных технологий»

РАБОТА ПРОВЕРЕНА  
Рецензент

\_\_\_\_\_ А.Ю.Конорев

“ \_\_\_ ” \_\_\_\_\_ 2019 г.

ДОПУСТИТЬ К ЗАЩИТЕ  
Заведующий кафедрой ИКТ

\_\_\_\_\_ С.Н.Даровских

“ \_\_\_ ” \_\_\_\_\_ 2020 г.

**Построение нейросетевого экстраполятора многокомпонентного  
радиотехнического сигнала**

ПОЯСНИТЕЛЬНАЯ ЗАПИСКА К ВЫПУСКНОЙ КВАЛИФИКАЦИОННОЙ РАБОТЕ  
ЮУрГУ – Д.11.05.01.2019.371.00 ПЗ

Консультанты:

По экономике

\_\_\_\_\_ Р.Ш.Закиров

“ \_\_\_ ” \_\_\_\_\_ 2019 г.

Руководитель работы:

\_\_\_\_\_ А.Н.Рагозин

“ \_\_\_ ” \_\_\_\_\_ 2019 г.

По охране труда

\_\_\_\_\_ И.С.Окраинская

“ \_\_\_ ” \_\_\_\_\_ 2019 г.

Автор работы:

студент группы КЭ-678

\_\_\_\_\_ А.А.Разумов

“ \_\_\_ ” \_\_\_\_\_ 2019 г.

Нормоконтролер:

\_\_\_\_\_ В.Д.Спицына

“ \_\_\_ ” \_\_\_\_\_ 2019 г.

## РЕФЕРАТ

Разумов А.А. Построение нейростевого экстраполятора многокомпонентного радиотехнического сигнала. – Челябинск: ЮУрГУ, ВШЭКН; 2019, 98 с., 10 табл., 39 ил., библиографический список – 25 наим., 1 прил., 6 листов чертежей ф. А1.

Объектом исследования являются искусственные нейронные сети, которые за последние 20 лет зарекомендовали себя как универсальный инструмент для решения множества задач.

Цель работы – построение нейросетевого экстраполятора многокомпонентного радиотехнического сигнала.

В процессе выполнения работы проведен анализ методов предварительной цифровой обработки данных и методов обучения искусственных нейронных сетей.

В ходе выполнения работы были разработаны специальные методы предварительной обработки данных для улучшения качества функционирования экстраполятора, обучены искусственные нейронные сети и написан программный код для реализации экстраполяции.

Работа была реализована с помощью программный продуктов: MathWorks MatLab 2015b; Python 3.6; Microsoft Word.

Разработанный экстраполятор может быть использован для прогнозирования различных временных рядов, радиотехнический сигналов и траекторий движения летательных аппаратов.

					ЮУрГУ-Д.11.05.01.2019.371.00 ПЗ		
Изм.	Лист	№ докум.	Подпись	Дата			
Разраб.		Разумов А.А.			Лит.	Лист	Листов
Проверил		Рагозин А.Н.			Д	3	98
Н. Контр.		Спицына В.Д.			ЮУрГУ Кафедра ИКТ		
Утв.		Даровских С.Н.					

## ОГЛАВЛЕНИЕ

СПИСОК СОКРАЩЕНИЙ И ОБОЗНАЧЕНИЙ .....	6
ВВЕДЕНИЕ .....	7
1 Анализ аналогов .....	11
2 Нейронные сети, их структура и основы функционирования .....	15
2.1 Математическая и биологическая структуры нейронов .....	15
2.2 Возможности нейронных сетей .....	19
2.3 Структуры и основные функции нейронной сети .....	20
2.4 Физический и геометрический смысл работы сети .....	22
3 Методы и способы улучшения экстраполяции .....	26
3.1 Методы обучения сети .....	26
3.2 Цифровая обработка входных данных .....	30
3.3 Способы улучшения экстраполяции .....	34
4 Конструирование нейросетевого экстраполятора многокомпонентного радиотехнического сигнала .....	45
4.1 Способы реализации экстраполяции радиотехнического сигнала .....	45
4.2 Экстраполятор на нейронных сетях .....	46
4.3 Пример экстраполяции многокомпонентного радиотехнического сигнала .....	55
5 Организационно-экономический раздел .....	58
5.1 Сетевое планирование .....	58
5.2 Построение сетевого графика .....	58
5.3 Расчет параметров событий сетевого графика .....	63
5.4 Расчет параметров работ сетевого графика .....	65
5.5 Расчет стоимостных параметров научно-исследовательской работы .....	68

5.6 Экономический эффект разработки .....	69
6 Безопасность жизнедеятельности.....	71
6.1 Основные негативные факторы при работе с ЭВМ.....	71
6.2 Параметры микроклимата помещения.....	72
6.3 Требования к уровням шума .....	74
6.4 Параметры мониторов и освещенность рабочего места .....	75
6.5 Параметры электромагнитных излучений.....	77
6.6 Эргономика рабочего места .....	78
6.7 Характеристики нервно-психической напряженности труда на ЭВМ.....	79
6.8 Способы и средства защиты от вредных факторов .....	79
6.9 Организация собственного рабочего места .....	80
ЗАКЛЮЧЕНИЕ .....	83
БИБЛИОГРАФИЧЕСКИЙ СПИСОК.....	85
ПРИЛОЖЕНИЕ А .....	87

## СПИСОК СОКРАЩЕНИЙ И ОБОЗНАЧЕНИЙ

АЧХ – амплитудно-частотная характеристика;

БЖД – безопасность жизнедеятельности;

ВДТ – видеодисплейный терминал;

ИНС – искусственная нейронная сеть;

КИХ – конечная импульсная характеристика;

ЛА – летательный аппарат;

НС – нейронная сеть;

ПЗ – пояснительная записка;

ПЭВМ – персональная электронно-вычислительная машина;

СГ – сетевой график;

СКО – среднеквадратическое отклонение;

ТЗ – техническое задание;

ФНЧ – фильтр нижних частот;

ЭВМ – электронно-вычислительная машина.

## ВВЕДЕНИЕ

Каждый из нас хоть раз задумывался о будущем, начиная с предположения о том, какая погода будет следующим днем и заканчивая динамикой поведения сложных зависимостей на месяцы вперед, не говоря уже о возможных прогнозах модернизации технологий, заглядывая далеко в будущее. Предсказанием занимались испокон веков. Многие люди хотели узнать, что с ними произойдет, какие события их ожидают. Такое желание подталкивает людей анализировать происходящее и предвидеть грядущие явления. Тяготение человека к новому лежит в основании движущей силы процесса модернизации и прогресса, а конкуренция выдвигает самый лучший вариант с высоким качеством использования. Таким образом, сам человек оказывается фундаментальным двигателем научно-технического прогресса.

На данном этапе, ввиду быстрого развития электроники, технологий, программного обеспечения, прослеживается огромный рывок в способах обработки, анализе и конвертировании данных в цифровом виде. Благодаря этому человек имеет в своем распоряжении практически неограниченное количество ресурсов для реализации множества идей и проектов. Поэтому возникает необходимость прибегать к средствам постоянного контроля над всевозможными эмпирическими зависимостями, временными рядами и другими для установления возможных способов развития в будущем.

Понимание предсказаний ограничивается разумными рамками, в которых есть место для собственного вложения и инноваций. На основании предшествующего поведения зависимостей выстраивается наиболее оптимальное и вероятностное изменение наблюдаемой величины, это и есть экстраполяция. Экстраполяция проводится на искусственных нейронных сетях (ИНС). На сегодняшний день направление «машинное обучение», в которое входят ИНС, имеет интенсивный характер развития. С каждым годом это направление становится актуальнее, необходимость использовать искусственный интеллект возрастает, т.к. происходит глобальная автоматизация процессов, где в наблюдении и контроле ситуации человеком нет необходимости.

Впервые в 1943 г. в работе Маккалока и Питтса «Логическое исчисление идей, относящихся к нервной активности» были сформулированы способы моделирования определенных функций мышления живого организма. В своей работе они исходили из некоторой определенной схемы взаимодействия нейронов. Авторы показали возможность построения логических сетей, функционирование которых эквивалентно функционированию нейронных сетей, характеризуемых теми или иными физиологическими свойствами. Идеи Маккалока и Питтса нашли дальнейшее развитие в огромном количестве работ. В 1962 г. в книге Ф. Розенблатта «Принципы нейродинамики» сделана попытка изложения статистических принципов построения мозгоподобных устройств, основанных на известных фактах нейрофизиологии и психологии живых организмов.

В настоящее время существует множество методов прогнозирования. Некоторые наиболее распространённые способы далее будут рассмотрены, проанализированы и сравнены с ИНС. Если рассматривать прогнозирование с помощью статистической обработки, то затраты сил, времени, денег уходит намного больше, при этом необходимо иметь специалиста, разбирающегося в этом. С точки зрения корреляционной составляющей, рассматривать влияние каждой временной точки на другие и их дальнейших комбинаций нецелесообразно. Нейронные сети исключают недостатки статистического метода и могут быть автоматизированы и интегрированы в любые системы обработки сигналов и эмпирических зависимостей. Из этого можно сделать вывод, что под влиянием всех минусов, статистика уступает нейронным сетям.

Также используют прогнозирование на основе Фурье-преобразования, основываясь на спектральных характеристиках, которые могут в достаточной мере описывать предысторию сигнала.

В современной радиолокации используются теории автоматической обработки радиолокационной информации. Как наиболее значимые стоит указать труды Б.Р. Левина [1], В.И. Тихонова [2], Я.Д. Ширмана [3]. В перечисленных работах описаны методы, которые осуществляют автоматическую обработку радиолокационной информации. Но в большинстве случаев их концепции ссылаются на положения клас-

сической теории радиолокации, опирающиеся на предположения, большинство из которых не выполняются на практике. Действительно, оценки эффективности показывают, что в достаточно простых условиях современные радиолокационные средства успешно справляются со своими задачами, однако при усложнении условий: интенсивный налет, нестационарные и негауссовы помехи – их эффективность может резко снижаться. Непредсказуемость внешней обстановки и высокая динамика её изменения создают непреодолимые трудности формализации алгоритмов и обеспечения высокого качества их работы. Актуальность темы нашего исследования следует из необходимости решения задач, таких как, распознавание ситуаций, прогнозирование обстановки. Оптимальным решением этих задач выступает применение искусственных нейронных сетей

Цель исследования – построение нейросетевого экстраполятора многокомпонентного радиотехнического сигнала.

Объект исследования – искусственные нейронные сети.

Предмет исследования – предварительная обработка данных, как способ улучшения функционирования нейросетевого экстраполятора.

Задачи исследования:

- изучить внутреннюю настройку нейронной сети для выделения наиболее эффективного функционирования;
- исследовать и предложить варианты цифровой обработки данных;
- разработать наиболее эффективные способы по улучшению качества экстраполяции нейронной сетью;
- сконструировать многокомпонентный прогноз.

Методы исследования

Теоретические методы: изучение, анализ, сравнение, литературы по проблеме исследования.



Практические методы: конструирование нейронных сетей, составление программ по теме исследования и проверка опытным путем их результативности.

Теоретическая значимость: в работе описаны новые методы по повышению продуктивности экстраполяции.

Практическая значимость: данная работа может служить практическим руководством для реализации высоко эффективного прогнозирования.

## 1 Анализ аналогов

В отечественных технологиях для оценивания состояния динамической системы используется фильтр Калмана. Этот фильтр является универсальным инструментом решения задач в инженерных, экономических и других отраслях. В частности, вторичная обработка радиолокационной информации полностью опирается на алгоритм Калмана. Процесс этой обработки заключается в формировании и сопровождении траекторий от обнаруженных целей (летательные аппараты). Для сглаживания и экстраполяции координат траекторий используется упрощенный фильтр Калмана в виду высокой вычислительной сложности. Такой фильтр получил название Альфа-Бета. Также необходимо кратко рассмотреть алгоритм работы Альфа-Бета фильтра для выявления его отрицательных сторон.

После возникновения отметки происходит перевычисление координат и составляющих скорости траектории. Во время сопровождения производится сглаживание траектории с помощью Альфа-Бета фильтра. При этом составляющие координат и скорости пересчитываются согласно выражениям:

$$X_{new} = X_{old} + \alpha \cdot (Y - X_{old}), \quad (1)$$

$$V_{new} = V_{old} + \beta \cdot (Y - X_{old}), \quad (2)$$

где  $X_{new}$ ,  $X_{old}$  – вектора старых и новых значений координат местоположения цели;

$V_{new}$ ,  $V_{old}$  – вектора уточненных и старых значений координат скорости;

$Y$  – вектор последнего измерения координат цели;

$\alpha$ ,  $\beta$  – параметры фильтра сглаживания.

Фактически, эти параметры — весовые коэффициенты к ошибкам прогноза позиционирования и скорости объекта. Альфа и бета остаются постоянными во время работы фильтра и задаются изначально как константы. Они выбираются исходя из

условия удовлетворения противоречивым требованиям наилучшего сглаживания измеренных координат целей и достаточно быстрой реакции на внезапные маневры целей.

Для оценки качества отождествления статданными методами и предложенным алгоритмом ассоциативного воспроизведения отметок была разработана математическая модель, позволяющая получать статистические характеристики полноты и достоверности выдаваемой потребителю информации, на основе множества реализации.

Однако возникает сложность в повышении качества его функционирования из-за непростой траектории маневрирующих целей и появлением ошибки Калмановской фильтрации по причине запаздывания следящего за целью фильтра. Было много попыток описания маневров с помощью традиционных методов статистического анализа. При этом использовались Марковские цепи, многоцелевые параллельные модели и другие [4]. Но они не привели к успеху. В [5] показано, что при определенных маневрах цель сбрасывается с сопровождения.

В то же время известно, что нейронные сети способны реализовывать нелинейную фильтрацию, что позволяет рассматривать эти модели в качестве альтернативы традиционным методам сглаживания и экстраполяции координат. В [6], было показано что обучение нейронной сети может рассматривать как идентификация нелинейной динамической системы. Предложенный подход можно сравнить с группой независимых калмановских фильтров, организованных в виде параллельной структуры. Поэтому многослойные нейронные сети являются одним из наиболее перспективных вариантов для улучшения сопровождения маневрирующих целей. Основная идея использования нейронных сетей в качестве фильтра для сглаживания и экстраполяции координат основывается на известной способности нейронных сетей проводить экстраполяцию временного ряда.

Другими распространенными решениями являются авторегрессионные и экспоненциальные классы прогнозирования. Указанные методы относятся к приемам, осуществляющим сглаживание временных рядов, радиотехнических сигналов и других

зависимостей. Суть этих приемов сглаживания сводится к замене фактических уровней временного ряда расчетными уровнями, которые в меньшей степени подвержены колебаниям. Это способствует более четкому проявлению прогнозируемых состояний.

В частности, подвид авторегрессионной модели является метод простой скользящей средней. Он применим, если графическое изображение динамического ряда напоминает прямую. Когда вид ряда имеет изгибы и для исследователя желательно сохранить мелкие перегибы, то применение простой скользящей средней нецелесообразно. Если для процесса характерно нелинейное развитие, то простая скользящая средняя может привести к существенным искажениям. В этих случаях следует обратиться к взвешенной скользящей средней. Следует отметить, что процедуры скользящих средних представляют собой важное аналитическое средство, обладая рядом бесспорных достоинств, к таким можно отнести, простота вычисления и интерпретации и др. Однако при этом их использование требует определенного опыта исследователя.

Для класса экспоненциальных кривых, в отличие от предыдущих, характерной является зависимость приростов от величины самой функции. Эти кривые хорошо описывают процессы, имеющие «лавинообразный» характер, когда прирост зависит от достигнутого уровня функции. В основе лежит идея постоянного пересмотра прогнозных значений по мере поступления фактических данных. К плюсам можно отнести простоту и прозрачность расчетов, достаточную сходимость действия процесса. К минусам относятся сложность подбора начальных условий и определения коэффициентов модели, а также низкая адаптивность к нелинейным процессам и внешним факторам.

Таким образом, авторегрессионные и экспоненциальные методы прогнозирования используют полиномы или кривые роста для выравнивания временных рядов с последующим расчетом точечного и интервального прогнозов. Такой вариант развития событий отличается трудоемким анализом текущих и предыдущих значений наблюдаемой динамической системы что не дает гарантий на точное экстраполирование.

Реализация нейросетевых вычислений сегодня не является проблемой, существует множество программных средств, позволяющих оперировать нейронными сетями. Все вычисления удобно производить в пакете прикладных программ MatLab, однако он является коммерческим продуктом. В противном случае существует высокоуровневый язык программирования Python, который предоставляется бесплатно. В то же время уже написано и реализовано множество библиотек, поддерживающих машинное обучение, в состав которых входят искусственные нейронные сети.

## 2 Нейронные сети, их структура и основы функционирования

### 2.1 Математическая и биологическая структуры нейронов

Модель мозга является камнем преткновения для понимания человеком функционирования живого организма. Существует множество теорий, описывающих систему мозга известными, легко поддающимися анализу свойствами, с целью определения основных характеристик мозга и заложенных в нем логических возможностей. Ученые, специализирующиеся в различных направлениях, философия, биология, математика, предложили множество моделей мозга. В общем случае, существует основное положение, играющее основополагающую роль в теории функционирования мозга. Большинство современных теоретиков придерживаются этого мнения. Основные свойства мозга определяются топологической структурой сети нервных клеток, или нейронов, и динамикой распространения импульсов в этой сети.

Для понимания нейрона прототипа необходимо знать устройство его оригинала.

Нейрон – это нервная клетка живого организма представляет собой элемент, который может находиться в двух состояниях – возбуждения и торможения. Нейрон имеет более сложную организацию, чем триггер, – элемент с двумя устойчивыми состояниями.

Схематическое изображение нейрона приведено на рисунке 2.1. Он состоит из трех основных частей: тела клетки (сомы), дендритов и аксона (нейрита).




Рисунок 2.1 – Строение биологического нейрона

Тело клетки нейрона отвечает за управление расходом энергии, питание, обновление ресурсов и другие процессы.

Дендриты (древовидные отростки) – это входы, по которым к телу клетки подводятся импульсы раздражения. Число отростков дендритов может достигать сотен, а их длина колеблется от долей миллиметра до десятков сантиметров. Они образуют густо ветвящееся дендритное дерево разной формы.

Аксон является выходом, по которому проводится возбуждение из клетки. Он может иметь длину от долей миллиметра до 1,5 м. На конце аксон разветвляется на множество ветвей. Он передает выходные сигналы нейрона на дендриты других нейронов.

Области контакта нервных клеток друг с другом называются синапсами. Синапс проводит возбуждение только в одном направлении – с окончаний аксона одного нейрона на дендриты и сому другого. Каждый нейрон может возбуждаться через множество синаптических контактов, расположенных вдоль дендритов и тела нейрона. Число синапсов крупного нейрона может достигать тысяч.

Одним из самых важных свойств нейрона является – способность к пространственному и временному суммированию раздражений. Это обуславливает сложность и гибкость их логических возможностей.

Пространственное суммирование заключается в том, что уровни отдельных раздражений, недостаточные для возбуждения нейрона, могут быть приложены к нему одновременно через несколько синапсов, что вызывает в результате возбуждение нейрона.

Временное суммирование состоит в том, что слабые раздражения, следующие одно за другим через достаточно короткие промежутки времени, также приводят к возбуждению нейрона, так как происходит не мгновенное, а экспоненциальное затухание действия отдельного импульса.

На рисунке 2.2 изображена математическая модель нейрона. Он состоит из входов, на которые подаются числа, весов (те же синапсы), смещения  $b$ , сумматора и активационной функции. Поступающие на входы числа умножаются на соответствующие веса, после чего произведения суммируются. Эта сумма всех результатов не является окончательным решением и для выдачи готового результата используется функция активации.

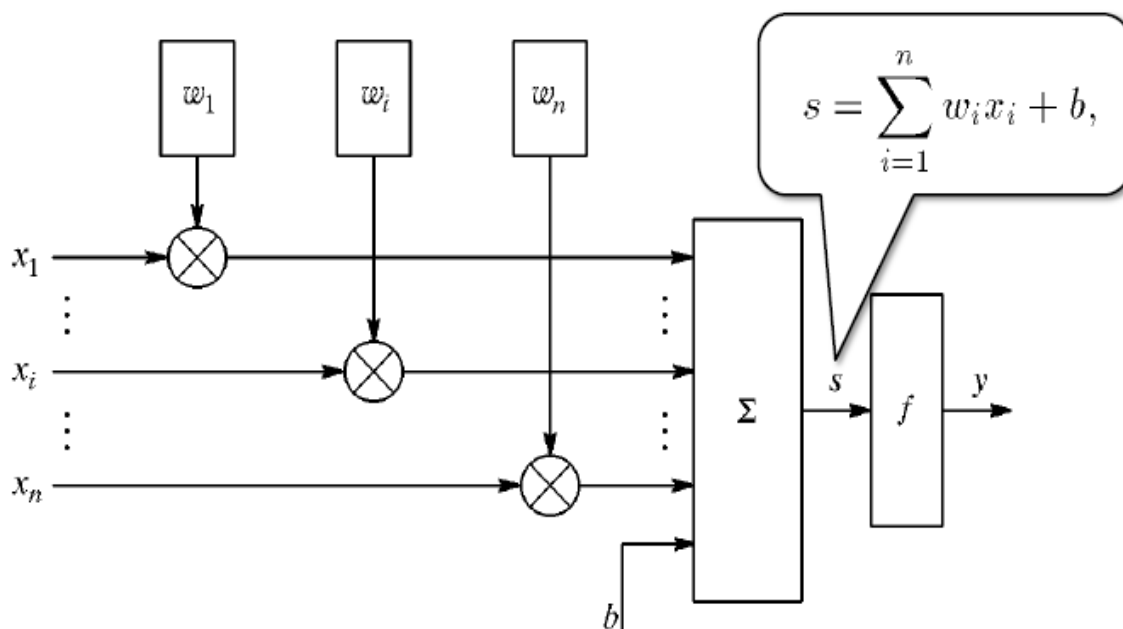


Рисунок 2.2 – Математическая модель нейрона



Функция активации — это способ нормализации входных данных. То есть, если на входе будет большое число, пропустив его через функцию активации, вы получите выход в нужном диапазоне. Функций активации достаточно много: Линейная, Пороговая, Сигмоида (Логистическая) и Гиперболический тангенс. Главные их отличия — это диапазон значений. Вариации функций активации представлены на рисунке 2.3.




Рисунок 2.3 – Функции активации

Один из видов нейронов – это перцептроны, введенные Фрэнком Розенблаттом в 1957 г. Перцептроны являются генотипными моделями с механизмом памяти, который позволяет им обучаться воздействиям на стимулы в различных типах экспериментов. В каждом варианте исследования объектом является экспериментальная система, включающая в себя перцептроны, определенную окружающую среду и процедуру обучения или внешнюю обучающую систему. Результаты такого анализа могут быть сопоставлены с результатами других экспериментов, что позволяет оценить преимущество или недостаточность.

Перцептроны не предназначены служить точной копией какой-либо конкретной нервной системы. Они представляют собой упрощенные сети, созданные для изучения закономерных взаимосвязей между организацией нервной сети, структурой окружающей ее среды и «психологическими» свойствами, которыми может обладать данная сеть. Чаще всего они представляют собой предельно упрощенную модель центральной нервной системы.

В применении к модели мозга использование нейронов столь сложного вида привело бы к тому, что система стала бы необозримой и неподдающейся анализу аналитическими и математическими средствами. Однако при этом не следует забывать, что биологический нейрон значительно сложнее и один такой нейрон способен сочетать в себе функции, для реализации которых потребовалась бы целая сеть упрощенных нейронов.

Таким образом, общая картина нервной сети представляется в виде системы, состоящей из большого числа генераторов сигналов, имеющих каждый один или более выходов, на которых могут появляться нервные импульсы. Эти импульсы могут различаться по частоте и до некоторой степени по амплитуде.

## 2.2 Возможности нейронных сетей

Внедрение искусственных нейронных сетей на сегодняшний день имеет интенсивный характер развития. С каждым годом это направление становится актуальнее, необходимость использовать искусственный интеллект возрастает, этого требует глобальная автоматизация процессов, используемых в обществе.

Нейронные сети способны решать множество численных вопросов, такие как, интерполяция, аппроксимация, экстраполяция, классификация, кластеризация.

Искусственные нейронные сети используются для разных задач. Они были основаны на предположении о работе нейронов низшего уровня в мозге, но непосредственного отношения к нему не имеют, а позаимствовали только структуру и параллелизм. Нейронная сеть является нелинейной и представляет собой алгоритмический аппарат, функционирующий на квазинеуронах, которые реализуют простейшие алгебраические действия с последующей их подстройкой. Основной механизм работы

ИНС: во время обучения на вход подается сигнал, который посредством возбуждения нейронов изменяется таким образом, чтобы минимально отличаться от целевой функции, которая является последующими значениями входного сигнала. Под целевые значения или желаемый результат подгоняются входные – это процедура называется обучение с учителем.

Также они нашли применение во многих областях техники, где используются для решения многочисленных прикладных задач:

- построение систем автоматического пилотирования самолетов и других систем, имитация траекторий полета;

- автоматическое чтение документов и их контроль, оценки эффективности кредитных вложений;

- управления оружием, слежение за целями;

- выделение и распознавание объектов;

- обработка звуковых, радиолокационных и телевизионных изображений, постановки и подавления помех, идентификация сигналов и изображений;

- анализ кредитных потоков, оценка недвижимости, прогнозирование стоимости валюты;

- сжатие и отображение данных, распознавание речи, классификация гласных звуков, преобразование текста в речь.

Этот перечень можно продолжить и далее. Широкое применение нейронных сетей, значительные ресурсы, вкладываемые в создание программного обеспечения и аппаратуры для реализации нейронных сетей, показывают, что имеется большая заинтересованность в разработке искусственных нейронных сетей.

### 2.3 Структуры и основные функции нейронной сети

Искусственная нейронная сеть состоит из некоторого множества элементов, генерирующих сигналы («нейронов»), связанных в единую сеть. Нейрон – это вычислительная единица, которая получает информацию, производит над ней простые вычисления и передает ее дальше. Другими словами, каждый из этих элементов при получении соответствующего входного сигнала (поступающего либо из окружающей

среды, либо от других элементов сети) генерирует выходной сигнал. Каждый нейрон следующего слоя имеет соединения с каждым из предыдущего слоя, данное соединения называется синапсом. Синапс – это связь между двумя нейронами. У синапсов есть один параметр – вес. Благодаря ему, входная информация изменяется, когда передается от одного нейрона к другому. На рисунке 2.4 изображен пример искусственной нейронной сети.




Рисунок 2.4 – Искусственная нейронная сеть

Вид нейронной сети зависит от поставленной задачи, опытным путем выявлено, что для прогнозирования выгоднее применять двухслойные сети с настраиваемыми задержками. В процессе исследования можно варьировать как количество нейронов в первом слое, так и задержку, начиная с нулевой. Количество нейронов в первом слое подбирается вручную, но слишком большое количество для данной задачи не приемлемо. Существуют определенные зависимости между числом входов (количество нейронов равняется числу входов) и размером обучающей выборки, однако эти отношения на начальном этапе исследования не затрагивались, но отдавалось предпочтение к использованию экспериментального метода с установлением оптимального соотношения «число входов – польза».

Главные этапы к полному пониманию нейронных сетей заключены в их логических свойствах:

- топологическая структура, т.е. связями между элементами, генерирующими сигналы;
- набор функций распространения сигналов, или алгоритмов, управляющих генерацией и передачей сигналов;
- набор функций памяти, или алгоритмов преобразования свойств сети в результате активности. Можно сказать, сеть меняет свои параметры, чтобы лучше подстроится под реализацию какой-нибудь функции. Под своими параметрами понимается весовые коэффициенты.

Таким образом, если каждый из пунктов рассматривать не по отдельности, а в совокупности, то это значит, что на вход подаются значения, которые посредством возбуждения нейронов изменяются таким образом, чтобы минимально отличаться от значений, являющимися эталонными. Данный процесс называется обучением сети.

#### 2.4 Физический и геометрический смысл работы сети

Выражение (1) определяет смысл нейрона, из которых состоит сеть. Это значит, что каждый вход  $X$  взвешивается (количество входов  $N$  может быть любым) – умножается на определенный коэффициент  $\omega$ , а сумма всех произведений определяет уровень возбуждения нейрона.

$$\sum_{i=1}^n x_i \omega_i + b. \quad (1)$$

Пусть количество входов  $X$  равно двум. Тогда выражение (1) примет вид (2).

$$x_1 \omega_1 + x_2 \omega_2 + b. \quad (2)$$

Если рассмотреть это выражение на плоскости  $X_1$  и  $X_2$ , то уравнение (3) будет определять некую прямую в этой плоскости, которая разбивает пространство  $X_1 X_2$

на два подпространства. Причем расположение этой прямой будет зависеть от коэффициентов  $\omega_1$ ,  $\omega_2$  и  $b$ . Соотношение  $\omega_1$  к  $\omega_2$  устанавливает угол наклона прямой к осям. Также вектор  $\omega_1$  и  $\omega_2$  определяет координаты нормали к прямой.

$$x_1\omega_1 + x_2\omega_2 + b = 0. \quad (3)$$

На рисунке 2.5 изображена данная разделяющая прямая.

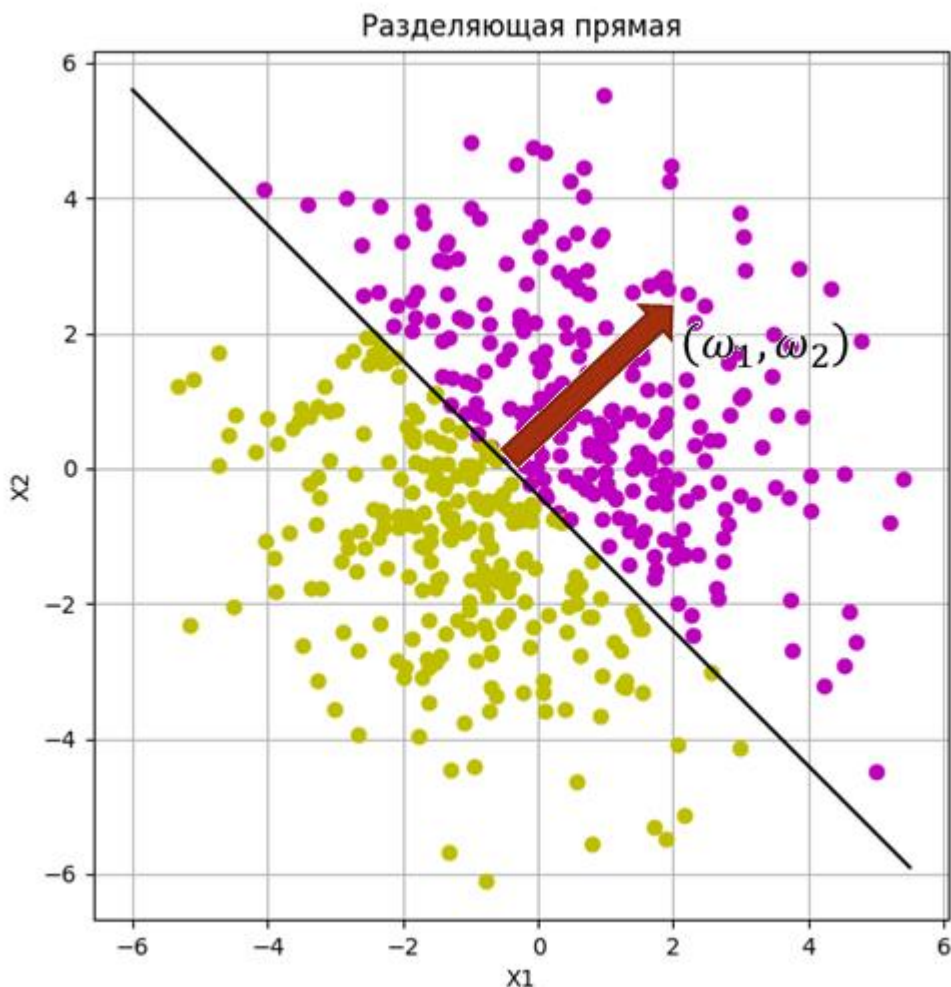


Рисунок 2.5 – Разделяющая прямая

В линейной алгебре выражение (3) называется линейной комбинацией, если точка с координатами  $X_1$ ,  $X_2$  лежит на прямой, то результат линейной комбинации равен нулю, если выше, то результат больше нуля, ниже – меньше нуля. В данном случае вектор нормали к прямой и будет диктовать ниже или выше находится точка. Куда направлен вектор там и верх.

В процессе реализации опытов с разделяющей прямой возник промежуточный вывод, на который натолкнул нас возникший вопрос. Насколько существенно рассматривать пространство  $X_1 \times X_2$  и насколько большую роль оно играет? Это пространство не несет в себе никакой информативности. Так как входные значения  $X_1$  и  $X_2$  в процессе обучения сети всегда принимают конкретные одни и те же значения. Следовательно, необходимо рассмотреть пространство коэффициентов  $\omega_1$  и  $\omega_2$ , потому что они являются динамическими.

В новой плоскости значения  $X_1$  и  $X_2$  будут задавать направление нормали, в сторону которой стоит двигаться, чтобы получить необходимую комбинацию весов  $\omega$ . Другими словами, каждая точка в пространстве представляет собой конкретную настройку всех весов (вектор веса). Веса должны лежать по одну сторону прямой, там, куда направлена нормаль. Только при выполнении этих условий скалярное произведение вектора весов и входного вектора будет давать правильный знак результата.

Подводя итог, если комбинаций входного вектора будет много, а результат должен быть действительный, то необходимо выбрать точки комбинации весов из пересечения подпространств. На рисунке 2.6 приведен пример с пересечением направлений нормалей разделяющих прямых.




Рисунок 2.6 – Разделяющие прямые



### 3 Методы и способы улучшения экстраполяции

#### 3.1 Методы обучения сети

Самая важная часть обучения нейронной сети — это тренировка, от неё напрямую зависит качество функционирования сети. Тренировка сети содержит в себе много настраиваемых параметров, каждый из которых необходимо выбрать и настроить, проанализировав всевозможные варианты. Первый шаг – инициализация сети – это расстановка значений весов синапсов и смещений, соответственно это и задает начальный курс, правильность выполнения задачи. Для каждого настраиваемого параметра существует значение по умолчанию, в инициализации стандартный вариант – случайная расстановка значений. Их значения выставляются небольшими, чтобы в процессе обучения не возникал паралич сети, вдобавок предотвращает ряд других некорректных случаев. Например, если выставить все значения одинаковые и большие, а функция имеет неравномерность распределения значений, то сеть не сможет правильно перестроить весовые коэффициенты. Также используют другие функции инициализации, они имеют ряд преимуществ, но не всегда являются наилучшими по сравнению со стандартной, возможно длительность обучения увеличиться на небольшое количество времени.

Второй шаг – это выбор глобального алгоритма минимизации ошибки. Исходя из вида обучающих данных накапливаются значения ошибок сети, ошибки сети характеризуются разностью целевых значений и полученных на выходе. Существует множество алгоритмов, их относят к трем группам, первого порядка с использованием градиента, второго порядка – методы Ньютона и Квазиньютоны. В каждой из групп имеется набор алгоритмов, в которых присутствуют свои достоинства и недостатки. Мы рассмотрели алгоритм градиентного спуска первого порядка и квазиньютонов алгоритм Левенберга-Маркварда. Оба метода исследовались на двухслойной нейронной сети. Алгоритм градиентного спуска для поставленной задачи один из нескольких с самой быстрой сходимостью, но имеющий маленькую устойчивость во

время обучения, проявляется это в отклонении от уменьшения ошибки, говоря другими словами, разность между выходными и целевыми значениями после нескольких итераций обучения может возрастать. Поэтому параметр максимального количества ошибок на проверочном множестве необходимо выставить вручную значением больше, чем установлено по умолчанию, чтобы обучение не застряло в относительном локальном минимуме. Также могут возникать случаи долгой сходимости в конце оптимизации – эта проблема должна быть решена самой нейронной сетью, при обнаружении «застывания» обучения, сеть «встряхивает» свои значения, добавляя в них случайную величину. Вторым методом Левенберга-Маркварда отличается высокой точностью аппроксимации на обучающем множестве, но время обучения довольно высоко и соответственно необходимо достаточное количество оперативной памяти, т.к. в процессе вычисления приходится хранить объемные матрицы Якоби и Гессе, а также производить с ними действия. Однако для экономии памяти можно настроить декомпозицию, которая позволяет хранить лишь части матрицы. Каждый из методов имеет внутри себя множество настраиваемых параметров, один из них – это метод одномерного поиска. Он обеспечивает поиск минимума вдоль заданного направления, на каждой итерации вычисляет величину шага исходя из минимума целевой функции, проделанные действия называют задачей минимизации функции одной переменной. Для каждого из алгоритмов метод одномерного поиска установлен свой метод по умолчанию, но их можно менять и задавать, исходя из опытов и личных предпочтений, начиная с простых, таких как метод золотого сечения, половинного деления и продолжая гибридными, которые содержат в себе комбинации более простых. Конечный результат оценивается своей функцией, он показывает отличие полученных данных от желаемых. Его также можно изменить, самые распространённые – это среднеквадратическое отклонение и среднее абсолютное отклонение. Вдобавок к полноценным алгоритмам имеется возможность подстраивать и варьировать величины, которые в удачном и правильном случае могут кардинально изменить ход обучения и повлиять на конечный результат. Такими параметрами являются, в случае градиентного спуска – это параметр скорости настройки, который используется для вычисления приращений весов синапсов, соответственно, чем больше его значение,

тем выше приращение, такая величина сохраняется на протяжении как минимум двух итераций и автоматически пересчитывается. В случае алгоритма Левенберга-Маркварда – это параметр «мю», данная величина воздействует на скорость сходимости и в зависимости от значения переключается между двумя методами аппроксимации. Рекомендуется выставлять значения не слишком маленькие, в пределах от 0,5 и до 1. Перечисленные выше параметры имеют субъективный характер и не являются идеальным вариантом для реализации экстраполяции, поэтому стоит проводить дальнейшие исследования с их использованием и комбинацией с другими, но категорические не использовать установленные по умолчанию.

Все эти основные параметры подстраивают нейронную сеть под определенную эмпирическую зависимость, делая всё, чтобы аппроксимированная функция в точности описывала целевые значения. Действительно, чем меньше разностная ошибка, тем лучше воспроизводится функция на обучающем множестве, однако слишком точная аппроксимация ведет к невозможности прогнозировать будущие значения, для которых не подверглись подстройке синаптические коэффициенты – это называется переобучением. Действие переобучения распространяется сугубо в рамках обучающей выборки. Поэтому, если количество исходных данных мало, то не стоит слишком точно их описывать. Возможное решение – это уменьшение количества нейронов в слое.

При достаточной размерности обучающей выборки стоит использовать алгоритм Левенберга-Маркварда, выходные данные более точно описывают поведение скачков функции, чем у градиентного спуска. Но оба варианта отражают динамику поведения сигнала и амплитуду локальных минимумов и максимумов. Подтверждение обуславливается полученными результатами, которые представлены на рисунке 3.1. В связи с этим появилась дилемма, какие алгоритмы использовать в процессе обучения, определенно конкретного алгоритма не существует, необходимо исследовать скомбинированные внутренности сети для каждого нового сигнала и определить наилучший, единого стандарта для прогнозирования в целом не существует.

На рисунке 3.1 проиллюстрировано прогнозирование сигнала с двумя методами обучения нейронной сети без использования дополнительных мер.




Рисунок 3.1 – Сравнение результатов прогнозирования двумя методами

В качестве примера на рисунке 3.1 приведены сигналы с использованием двух выше описанных методов обучения. С визуальной точки зрения наименьшее отклонение от истинных временных промежутков имеет зависимость, обучаемая методом Левенберга-Маркварда, подтверждением является численное значение стандартного отклонения, что меньше величины отклонения методом градиентного спуска.

Рассмотренные моменты ИНС можно анализировать и менять в лучшую сторону, возможно, для таких задач нужно нормировать данные в другом диапазоне, использовать другую – собственную функцию ошибок, пробовать разные варианты и просчитывать оптимальный. Вероятно, эти изменения позволят улучшить результат прогнозирования. Т.е. существует направление, в котором можно двигаться. Ведь добиться идеальной архитектуры и «внутренности» искусственной нейронной сети – это только первый шаг, второй – это удачное обучение с подстройкой всех весовых значений, которые позволят и обеспечат мгновенное прогнозирование в режиме реального времени.

### 3.2 Цифровая обработка входных данных

Цифровая обработка включает в себя множество этапов, которые должны быть реализованы на начальной стадии перед экстраполяцией сигнала. Благодаря многим исследованиям в данном направлении известно, что цифровая обработка является необходимым моментом, оказывающим положительное влияние как на аппроксимацию сигнала, так и на экстраполяцию. Для подтверждения этого мы осуществили некоторое количество опытов, связанных с аппроксимацией функций и сигналов.

Первое – это разбиение обучающих данных, которое играет большую роль в продуктивности сети и влияет на некоторые аспекты, например, косвенно затрагивает алгоритм оценки качества, а именно способ накопление ошибок сети, оказывает прямое влияние на количество входов и выходов нейронной сети. Формирование обучающих выборок делится на три типа: последовательное, групповое, смешанное. В последовательном случае входы и целевой вектор обучающих выборок формируется в виде массива формата `cell`, т.е. массив ячеек с одной строкой, в котором каждый элемент хранит реализации для определенного момента времени. Каждый момент времени является динамической величиной и содержит в себе  $N$  реализаций или выборок, их количество задается вручную, например, 10 значений функции, но данные величины не являются последовательными в исходной функции, а определенными моментами времени в каждой из выборок. Допустим, если есть две выборки по два значения в каждой, то в последовательном виде в первой ячейке будет лежать первые значения из каждой выборки. В групповом случае входы и целевой вектор формируются в виде массива формата `double`. Данный массив содержит временные последовательности для каждой реализации, разделенная функция на выборки остается неизменной. Размерность реализаций сугубо личный выбор.

Второе – это непосредственная цифровая обработка. Мы рассмотрели широкополосный недетерминированный сигнал, который представлен на рисунке 3.2 (часть всего сигнала). В случае, отсутствия цифровой обработки сигнала и обучение нейронной сети «сырыми» данными, то возникают некоторые проблемы, связанные с ограниченными ресурсами компьютера, продолжительным временем обучения, сильной

нагрузкой на простую архитектуру сети, такие как однослойные нейронные сети, и переобучением многослойных нейронных сетей.




Рисунок 3.2 – Исходный сигнал

Имеющийся недетерминированный сигнал имеет широкий амплитудный спектр, который можно разделить на несколько простых. Спектр представляет собой волновую структуру сигнала. С помощью фильтров нижних частот сигнал режется на составляющие. Существует множество вариантов разбиения волновых структур, мы рассмотрели один.

Метод предварительной цифровой обработки аппроксимируемого радиотехнического сигнала заключается в прохождении сигнала через гребёнку цифровых фильтров нижних частот и в получении на выходе гребёнки ФНЧ набора отфильтрованных компонентов исходного сигнала. Набор полученных компонентов сигнала с выхода гребёнки ФНЧ мы назвали вертикальным сигналом. То есть вертикальный сигнал, это многоканальный сигнал с выхода гребёнки ФНЧ, в данном эксперименте состоящей из 50 КИХ-ФНЧ с последовательно уменьшающимися частотами среза их частотных характеристик. При таком подходе произведена последовательная фильтрация шумов

с использованием параллельного набора цифровых ФНЧ. Полученные сигналы вместе с исходным изображены на рисунке 3.3 Низкочастотные волновые структуры оказывают наибольшее влияние на поведение сигнала, и в совокупности с другими наборами частот нейронная сеть лучше аппроксимирует точки.

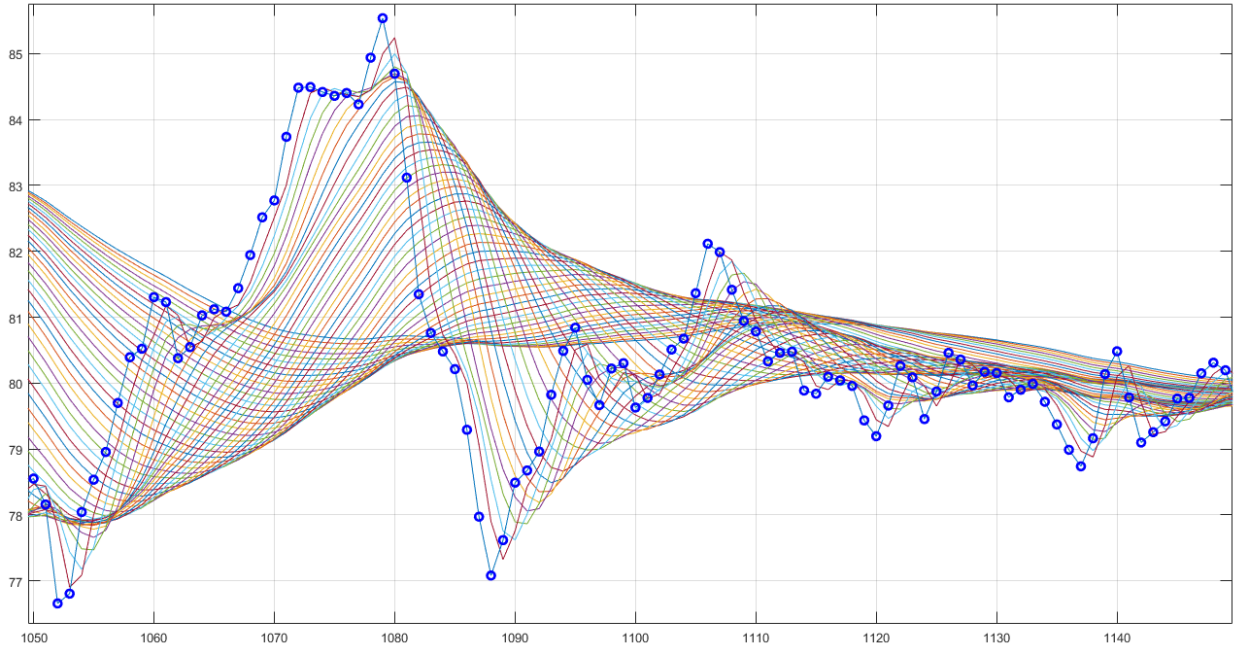


Рисунок 3.3 – Набор сглаженных (вертикальных) сигналов

На рисунке 3.4 продемонстрирован метод с использованием ФНЧ. График пурпурного цвета – аппроксимированная первая точка, график красного цвета – аппроксимированная вторая точка.

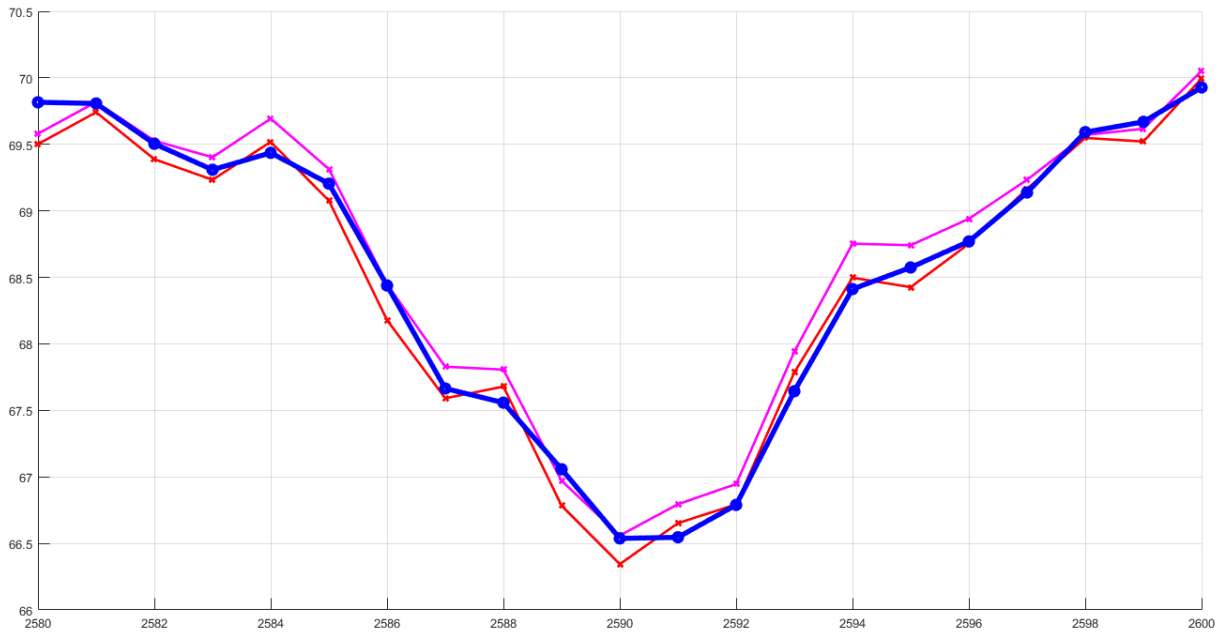


Рисунок 3.4 – Прогноз с обработкой

На рисунке 3.5 изображен пример прогноза сигнала без использования метода обработки. По рисунку 3.5 хорошо видно достаточное отклонение аппроксимированных точек в местах перегибов функции.



Рисунок 3.5 – Прогноз без обработки



Из графиков видно, что метод с обработкой имеет меньший разброс аппроксимированных значений относительно целевых, в перегибах исходного сигнала аппроксимированные точки достоверно его описывают. Подтверждением является значения среднеквадратических отклонений ошибок: метод с обработкой – 0,1917; метод без обработки – 0,2101. Полученное улучшение и уменьшение ошибки в конечном результате аппроксимации обусловлено расслоением горизонтального сигнала в вертикальный, и положительным влиянием низкочастотных волновых компонент на конечный результат аппроксимации.

Рассмотренный метод обработки как любой другой имеет плюсы и минусы. К минусам можно отнести: задержку сигнала после прохождения фильтра, хоть она и является минимальной, но всё же присутствует; продолжительное время обработки данных фильтрами. Плюсы – это улучшение качества прогноза, снижение нагрузки на нейронную сеть.

### 3.3 Способы улучшения экстраполяции

Нейронная сеть обладает рядом положительных свойств, к которым можно отнести способность находить скрытые зависимости между поданными на неё данными или сигналами. Поэтому возникла мысль проводить специальную обработку данных для достижения приемлемых результатов не только в аппроксимации, но и в прогнозировании.

Целью данной главы является анализ путей предварительной обработки данных для улучшения качества прогнозирования искусственных нейронных сетей. Прогнозирование или экстраполяция является востребованным направлением машинного обучения, так как прикладной характер имеет большой спектр решаемых направлений. Например, по спрогнозированным состояниям системы можно вовремя среагировать на неисправность или другую непредвиденную ситуацию.

Для информативности качества прогноза все результаты были зафиксированы и подвержены сравнительному анализу с другими методами обработки. В сравнительном анализе использовались три метода: горизонтальный, вертикальный, вертикальный со стабилизацией.

Обработка данных осуществлялась с помощью набора фильтров нижних частот. Дискретный фильтр нижних частот был спроектирован с помощью весовых функций для достижения минимальной групповой задержки сигнала и баланса между уровнями боковых лепестков амплитудно-частотной характеристики и шириной переходной зоны между полосами пропускания и задержания.

Подробнее о самих методах. Горизонтальный сигнал не подвержен каким-либо изменениям. Вертикальный сигнал является набором компонент, которые были отфильтрованы гребёнкой цифровых фильтров нижних частот. Вертикальный со стабилизацией – практически ничем не отличается от предыдущего, за исключением того, что при обучении нейронной сети на её выход подаются стабилизаторы, выполняющие роль некоего фиксатора устойчивости и робастности нейронной сети. На рисунках 3.6, 3.7, 3.8 приведены структурные схемы всех методов обработки с НС.

Внутренность сети особой важности не представляет, но стоит ограничиться некоторыми рамками. Используется нейронная сеть, способная аппроксимировать любую функцию. У такой сети количество скрытых слоев варьируется от одного и до трех. Для исследований была взята сеть с одним скрытым слоем, чтобы показать достижение приемлемых результатов даже с таким слабым инструментом. В качестве процедуры обучения выступал метод Левенберга-Маркварда, весь диапазон входных данных был разбит на обучение 70%, тестирование 15% и валидацию 15%.

Структурная схема горизонтального метода с нейронной сетью представлена на рисунке 3.6. Данный метод является стандартным и никаких манипуляций с обучающими данными при этом не производится. Это означает, что на нейронную сеть возлагается большая нагрузка в выстраивании зависимостей между входными и выходными значениями. Что в свою очередь может вызвать продолжительное время обучения, пропуск относительного глобального минимума ошибки и т.д.




Рисунок 3.6 – Структурная схема для горизонтальной функции

Для реализации поставленной цели исследования, мы проанализировали предварительную обработку данных что может и должно отразиться на требованиях как к самим нейронным сетям, так и к «железу». В роли предварительной обработки использовали конвертирование горизонтального сигнала в вертикальный. Мы отталкивались от определенного периода среза, который является основой для сглаженности сигнала и его требованиям к отношению сигнал-шум. Следующим этапом является конвертирование горизонтального сигнала в вертикальный за счёт гребёнки фильтров с последовательно увеличивающимся периодом среза каждого фильтра. Преобразование производится по мини-батчам. Т.е. каждый вектор входных данных горизонтального сигнала длиной  $n$  ( $n \in \mathbb{N}$ ) подается на параллельный набор цифровых ФНЧ, тем самым сформировав многоканальный сигнал, определяющийся матрицей  $n \times n$ , из которой отбираются все значения столбца под номером  $n$ , соответствующему одному временному интервалу. Следовательно, всю энергию горизонтального сигнала ужали в один временной момент вертикального сигнала, предшествующему прогнозируемому значению. Также существуют другие варианты комбинаций вертикального вектора из матрицы  $n \times n$ , но опыты с другими случаями не производились. Основным плюсом вертикального сигнала представляется совокупность сглаженных функций, обладающими волновыми и инерционными характеристиками, благодаря которым улучшается качество прогнозируемых точек.

Нейронная сеть является неким аппаратом, выслеживающим взаимосвязи между обучающими векторами. Конвертировав эти вектора в набор волновых функций, ко-

торые полностью описывают исходные данные, и обучив нейронную сеть ими, формируется объект, решающий несколько задач. К таким задачам относятся: выявление волновых зависимостей; обратное конвертирование в процессе активации нейронов; конечный прогноз данных. В противном случае, при применении горизонтального метода количество задач сужается до двух, однако нейронная сеть тратит больше «усилий» на поиск и формирование зависимостей. Исследование показало, что сформированные задачи в вертикальном методе играют положительную роль как для дальности прогноза, так и для его качества. Структурная схема вертикального метода с нейронной сетью представлена на рисунке 3.7.




Рисунок 3.7 – Структурная схема для вертикального сигнала

В продолжении улучшения качества функционирования сети рассматривались и использовались дополнительные меры, но при этом сохранялась пониженная нагрузка на НС. Другими словами, при формировании обучающих выборок вертикальным методом в целевые выборки добавлялись величины из входного вектора – так называемые стабилизаторы. Если представить входной вектор  $x = [x_1 \ x_2 \ x_3 \ x_4]$ , целевой вектор  $y = [y_5 \ y_6 \ y_7]$  (где  $y_5 = x_5$ ,  $y_6 = x_6$ ,  $y_7 = x_7$ ) и вектор на выходе гребёнки ФНЧ  $x' = [x_1' \ x_2' \ x_3' \ x_4']$ , то целевой вектор со стабилизацией должен выглядеть  $y' = [x_4 \ x_4' \ y_5 \ y_6 \ y_7]$ . При этом, сети навязывается некоторая инерционность, которая толкает и прижимает входные значения в направлении вероятных будущих значений. Количество стабилизаторов и вид обучающих векторов не ограничивается примером и может быть настроен как угодно, но выбор вида целевого вектора, с точки зрения наилучшей выгоды является темой исследования соответствующего направления. Выдвинутая гипотеза может иметь ошибочный характер по применению к другим исследованиям, но исходя из полученных результатов и опытов можно считать

выдвинутую гипотезу приемлемой для применения в прогнозировании временных рядов и других зависимостей. По проведенным экспериментам видно, что стабилизирующие свойства положительно влияют не только на прогноз низкочастотных зависимостей, но и на экстраполяцию быстрофлуктуирующих, которые характеризуются малым периодом среза. Структурная схема дополненного метода изображена на рисунке 3.8.




Рисунок 3.8 – Структурная схема для вертикального сигнала со стабилизаторами

Качественная и численная оценки являются основными видами представления окончательных результатов, менее важным, но далеко не самым последним служит визуальная оценка полученных результатов. На рисунке 3.9 виден прогноз третьей точки, представленные синими функциями с перекрестиями, которые накладываются на черные целевые функции. Этот прогноз осуществлялся горизонтальным методом.




Рисунок 3.9 – Экстраполяция горизонтальным методом

Следующий рисунок 3.10 нацелен на демонстрацию применения вертикального метода прогноза на том же самом временном отрезке.

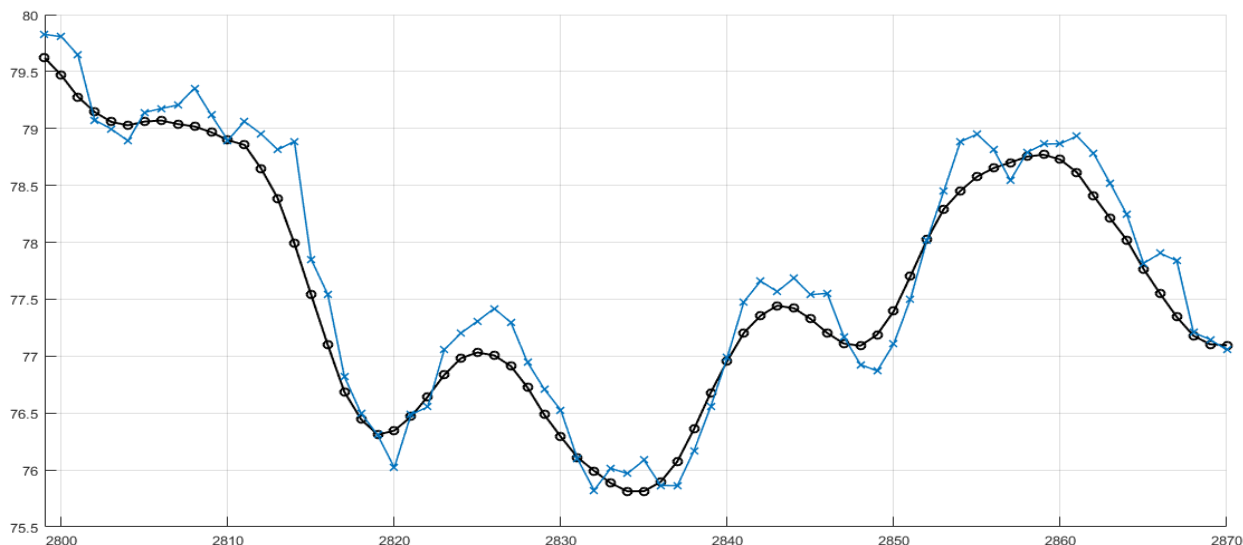


Рисунок 3.10 – Экстраполяция вертикальным методом

Хотелось бы заострить внимание на перегибах функций. Вертикальный метод, по сравнению с горизонтальным, качественно справляется с описанием выпуклостей и вогнутостей. С такой же уверенностью можно сказать и про стабилизационный метод, результат применения которого располагается на рисунке 3.11.

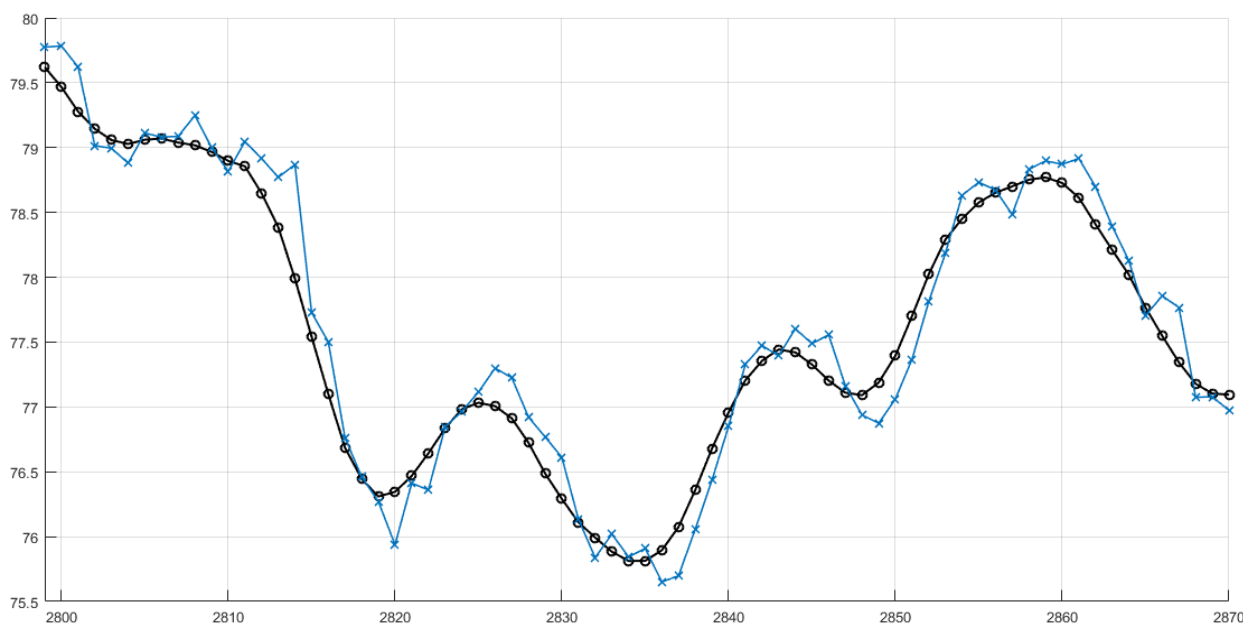


Рисунок 3.11 – Экстраполяция стабилизационным методом

Спрогнозированные значения рисунка 3.9 могут отражать динамику поведения, но не могут с приближенной точностью характеризовать амплитуду этой динамики. Ведь первоочередная цель – это достоверное описание изменения какого-либо параметра, а не его статичности. С чем в большей степени качества справляется вертикальный и стабилизационный методы. Полученная визуальная оценка подтверждается численным значением среднеквадратического отклонения спрогнозированных значений, представленная в таблице 3.1. Приведенные графики соответствуют исследованиям с периодом среза сигнала  $T=15$ . Выбранный период среза характеризует отсутствие в спектре сигнала высоких частот, которые являются не информативными и не желательными для описания их нейронными сетями.

Таблица 3.1 – Среднеквадратические отклонения методов

Метод	СКО 1-ой точки	СКО 2-ой точки	СКО 3-ей точки
Горизонтальный	0,0626	0,1463	0,2615
Вертикальный	0,0401	0,1045	0,2026
Стабилизационный	0,0399	0,1044	0,1944

На следующем графике рисунок 3.12 расположены ошибки третьих спрогнозированных точек для каждого метода (синий – горизонтальный, красный – вертикальный, черный - стабилизационный).




Рисунок 3.12 – Ошибки третьих точек

На рисунках 3.13, 3.14, 3.15 изображен черной функцией кривая сигнала, синим цветом кривая первого прогноза, оранжевым цветом кривая второго прогноза, желтым цветом кривая третьего прогноза для горизонтального, вертикального и стабилизационного соответственно.




Рисунок 3.13 – Горизонтальный прогноз






Рисунок 3.14 – Вертикальный прогноз

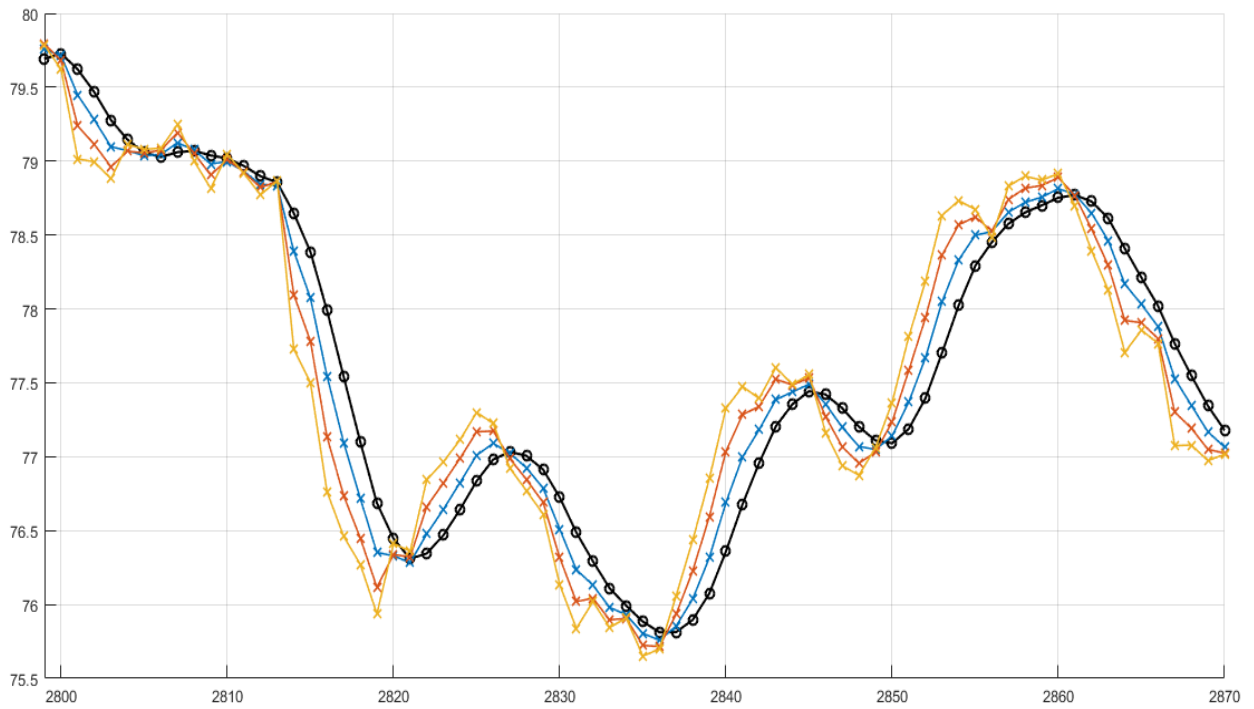


Рисунок 3.15 – Стабилизационный прогноз

На рисунке 3.16 произведен сравнительный анализ трех методов при разной сглаженности изначального сигнала. Ось абсцисс характеризует период среза ФНЧ, а именно, обратная величина от периода среза показывает граничную частоту фильтрации сигнала. Соответственно, чем больше период среза, тем более инерционный сиг-

нал. Далее этот сигнал преобразовывался тремя методами, результат которых проиллюстрирован тремя функциями. Где синяя функция – горизонтальный метод, а красная и черная – вертикальный метод и вертикальный со стабилизацией. Ось ординат показывает дальность прогноза – количество спрогнозированных точек при приемлемой и фиксированной ошибке, равная порогу ошибки. Проводились исследования с последовательным увеличением количества прогнозируемых точек, которые определяются среднеквадратическим и абсолютным отклонением от целевых. Также интервал, который участвовал только в прогнозе, характеризуется максимальным и минимальным значением абсолютного отклонения, а порог ошибки выбран средним от этих двух отклонений. Далее все точки, имеющие ошибку выше установленного порога, отсекались, что позволило определить предел прогнозируемых точек в каждом методе. Динамика функций рисунка 3.16 сохраняется одинаковой, но качество методов разное. Таким образом, опираясь на информативность графиков, видно, что два метода – вертикальный и вертикальный со стабилизацией имеют преимущество, как по дальности прогноза, так и по сглаженности сигнала.




Рисунок 3.16 – Зависимость дальности прогноза от периода среза

Обучения нейронных сетей производились для каждого случая однократно – без переобучения. В некоторых, но редких случаях результаты горизонтального метода

превосходили результаты двух других, которые могут обуславливаться случайным фактором. Однако путем взвешивания и усреднения отклонений всех спрогнозированных значений был получен окончательный результат, подтверждающий превосходство методов с дополнительной обработкой.

В нашем исследовании мы выяснили, что предварительная обработка данных является гарантом улучшения качества прогнозирования при использовании искусственных нейронных сетей. А также можно прийти к выводу, что вертикальный, стабилизационный методы обработки являются наилучшими и качественно влияют как на уменьшение ошибки прогнозирования, так и на дальность. В заключении этой главы необходимо отметить наличие множества других методов обработки данных, цифровых фильтров и других вариативных составляющих. Т.е. предел максимальной качественности не достигнут и может быть приближен благодаря использованию других искусственных методов и подходов.

## **4 Конструирование нейросетевого экстраполятора многокомпонентного радиотехнического сигнала**

### 4.1 Способы реализации экстраполяции радиотехнического сигнала

В нашем исследовании особый интерес представляют сложные недетерминированные зависимости, которые отличаются широким и насыщенным частотным спектром. С широким спектром может помочь справиться предварительной обработки данных с целью повышения качества функционирования, изложенные в предыдущей главе, которые в ряде экспериментов показали реальные результаты улучшения.

На начальном этапе необходимо было определить вектор движения, поэтому мы взяли простейшую архитектуру нейронной сети для проведения исследований. По набору результатов обучения сети быстрофлуктуирующим сигналом выяснилось отсутствие работоспособности и адекватности прогнозировать на любое количество точек. При реализации прогноза на неизвестном промежутке сигнала, архитектура прижала выходные значения к значениям входного вектора, т.е. выходные значения нейронной сети были завернуты внутрь диапазона значений входного вектора. Следовательно, посредством обучения сети сформировался объект очень похожий на аппроксиматор. К такому результату могли привести, либо отсутствие сложности архитектуры, либо наличие в спектре сигнала высоких частот. Второй вариант нам казался наиболее существенным, поэтому целью этой главы является рассмотрение и применение средств для уменьшения или исключения влияния выявленного фактора.

Первая мысль, которая пришла на ум – это подавление высоких частот сигнала фильтром низких частот, но тут возникли противоречия. Область применения методов экстраполяции очень широка и там, где быстрофлуктуирующие компоненты спектра не представляют никакой информации, то первое решение имело место быть и оказалось бы эффективным, однако в случае «полезности» высокочастотных компонент и неясности наличия шума, это может послужить причиной против использования первой мысли. Поэтому возникла вторая идея нарезать сигнал на составляющие, расплотив при этом количество нейросетей, которые будут эти составляющие

обрабатывать. Соответственно, такое представление прогнозирования, где учитывается каждая составляющая сигнала, следует определить, как реализация экстраполяции многокомпонентного радиотехнического сигнала.

Предложенный вариант имеет достаточное количество ответвлений и способов реализации. Каждая новая ветка развития событий является отдельной темой для разговора и обсуждения, таким образом об оптимизированности и наибольшей выгоде того или иного решения не может быть и речи. Важен только сам факт наличия улучшения качества прогнозирования и исключения глобальной проблемы, поставленной выше. Проверка некоторых вариаций затрагивает большое количество времени, поэтому далее мы рассмотрели и проанализировали один вариант, как наиболее эффективный, а также кратко сравнили со смежными.

#### 4.2 Экстраполятор на нейронных сетях

Выгоднее анализировать и орудовать отдельными объектами, нежели системой в целом. Следовательно, мы разбили широкополосный недетерминированный сигнал на некоторое количество составляющих, а именно, пять. Дифференциация производилась либо посредством ФНЧ, либо полосовым фильтром, но с дополнительным вычитанием компонент друг из друга. Конечно, можно применять другие цифровые методы, например, прямое и обратное преобразование Фурье с искусственным обнулением спектральных линий, но в нашем исследовании мы задействовали цифровой КИХ-ФНЧ с косинусоидально сглаженным АЧХ. Следовательно, «нарезка» сигнала происходила с помощью фильтра низких частот, т.е. для формирования компонент осуществлялось последовательное подавление частот с некоторым шагом от высоких и до средних. Таким образом, из целевого сигнала мы получили набор составляющих, которые изображены на рисунке 4.1, где сигнал черным цветом – исходный (приведена часть от всего сигнала), красные – сформированные компоненты. Используемые периоды среза ФНЧ для каждой из компоненты занесены в таблице 4.1.

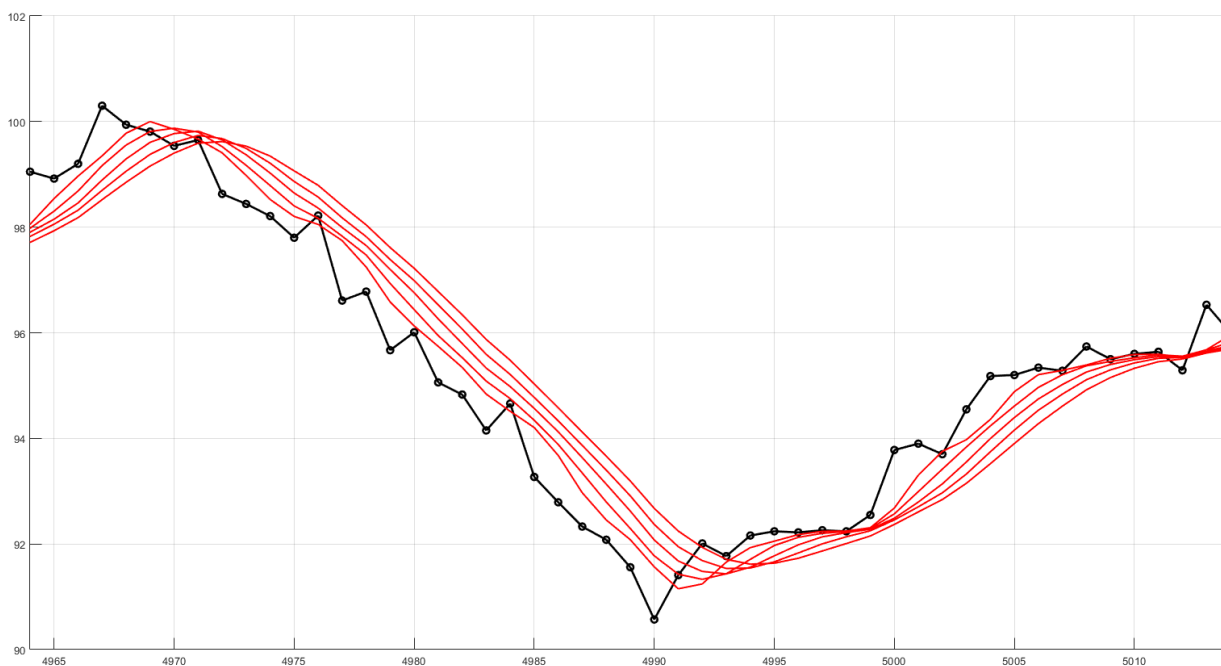


Рисунок 4.1 – Набор составляющих

Далее вступило в силу то, в каких пропорциях мы разбили весь спектр сигнала на составляющие. В зависимости от сглаженности составляющей, выбиралась дальность прогноза. Руководствуясь правилом: чем выше сглаженность, тем инерционнее сигнал, мы распределили количество выходов нейронных сетей. Для каждого из полученных сигналов необходимо распределить количество точек прогноза, которые отмечены в таблице 4.1. Приведенные значения в таблице не являются универсальными и могут быть заменены, но главное сохранить градацию.

Одним из характерных свойств повышения качества функционирования сети, важных для компоновки обучающих выборок, является определенный стабилизационный метод, изложенный в предыдущей главе. Предложенный механизм, несомненно, выполняет все наложенные на него обязательства, однако стоит отметить ограниченность количества прогнозируемых значений, вследствие повышенной загрузки нейронной сети из-за стабилизаторов. Возможное компромиссное решение лежит в использовании вертикального метода, который дает выигрыш в загрузке сети, однако уступает в точности прогноза. В обычном опыте обучения входные данные предъявляются последовательно и без манипуляций над ними, что

приводит к низкой точности экстраполяции. Поэтому наш выбор пал на стабилизационный способ обработки. Выбор периодов среза обусловлен диапазоном, в котором стабилизационный метод раскрывается в полную силу.

Не вникая в детальный анализ использованного улучшения, стабилизационный метод подразумевает конвертирование сигнала в набор вертикальных с помощью параллельного набора цифровых ФНЧ. На основе одной компоненты (красный цвет на рисунке 4.2) продемонстрируем на рисунке 4.2 набор вертикальных сигналов (разноцветные тонкие) на выходе гребёнки ФНЧ.

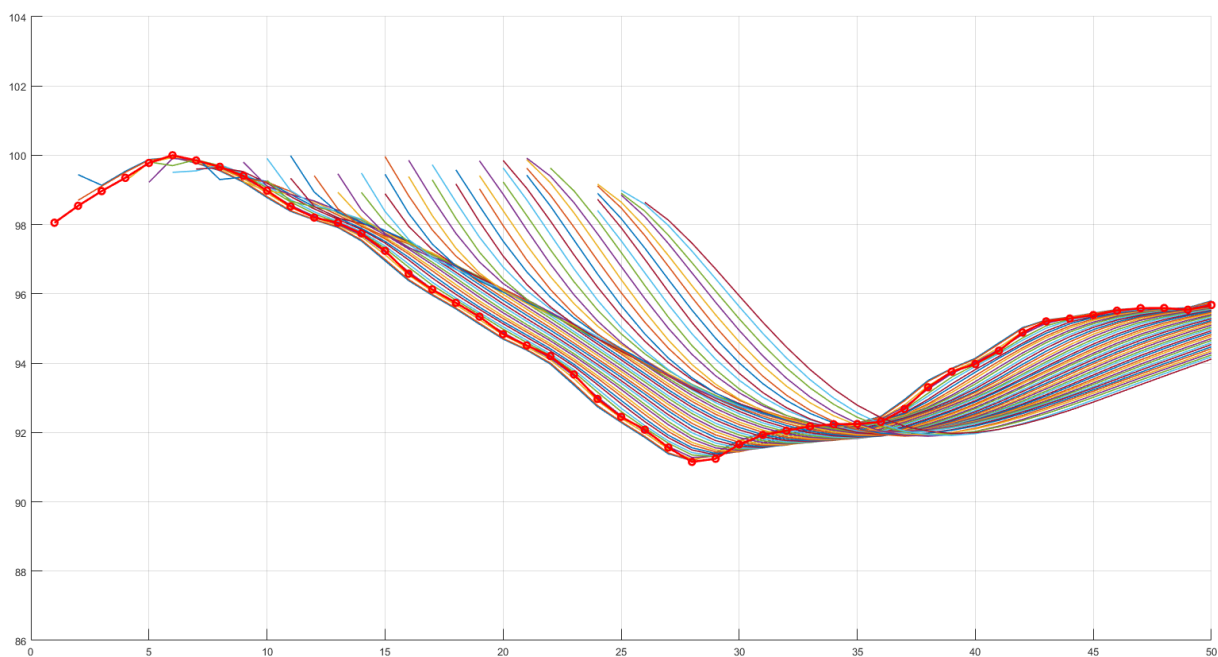


Рисунок 4.2 – Набор вертикальных сигналов

Следующим шагом необходимо было обучить соответствующее количество нейронных сетей тестовым множествам. В рамках исследования каждая нейронная сеть имеет один скрытый слой, содержащий 10 нейронов, пример которой изображен на рисунке 4.3.




Рисунок 4.3 – Структурная схема нейронной сети

В качестве процедуры обучения выступал метод Левенберга-Маркварда, весь диапазон входных данных был разбит на обучение 70 %, тестирование 15% и валидацию 15%, данные процентные соотношения от сигнала продемонстрированы на рисунке 4.4, также на рисунке 4.5 продемонстрирован спектр сигнала рисунка 4.4. Целевые вектора тестовых множеств содержат четыре стабилизатора, два из горизонтального, два из вертикального. Результаты обучения, среднеквадратические отклонения для всех сигналов также занесены в таблице 4.1. СКО рассчитывались по результатам прогнозирования на тестовом множестве без учета всех стабилизаторов. Весь временной интервал рисунка 4.1 отвечает промежутку вне диапазона обучающих выборок, который не был отдан нейронным сетям, следовательно, веса НС не обучены экстраполировать изображенные зависимости. Таким образом, для объективности результатов экстраполяции мы использовали указанный временной промежуток.

Таблица 4.1 – СКО сигналов на разных периодах среза

Период среза	Кол. точек прогноза	СКО
7	2	0,1777332
10	3	0,1898771
13	4	0,2009997
16	5	0,2156947
19	6	0,2249945






Рисунок 4.4 – Весь сигнал

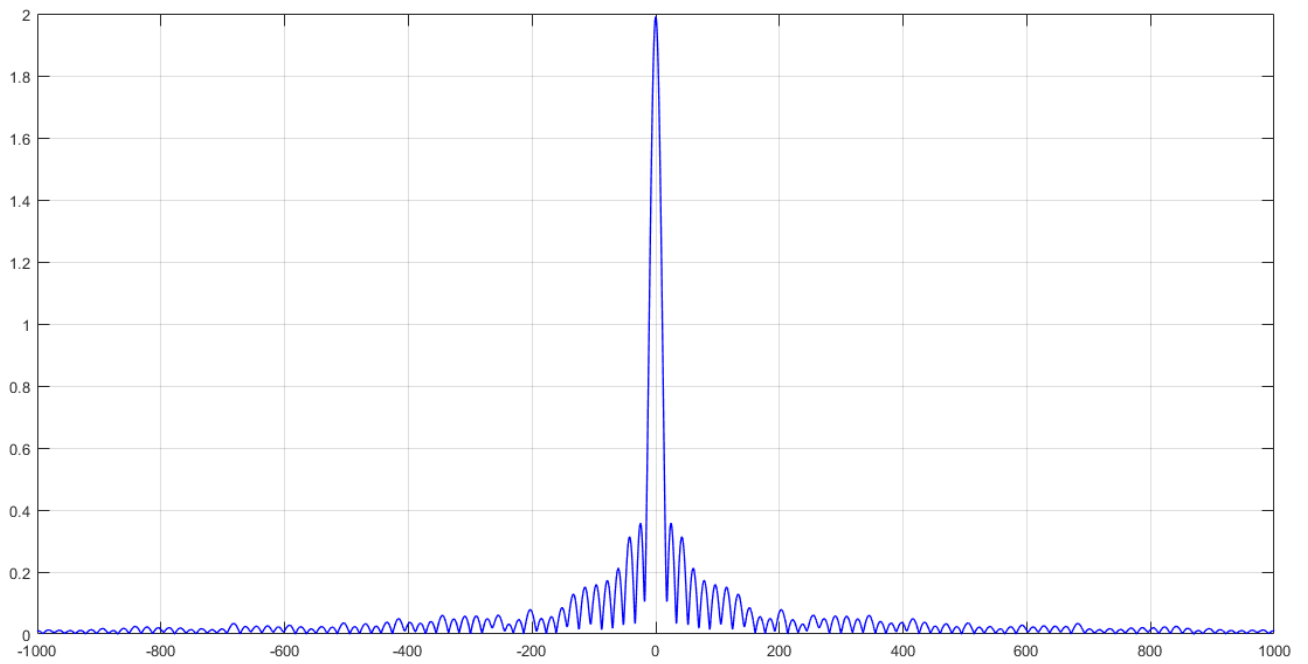


Рисунок 4.5 – Спектр сигнала

Каждая составляющая характеризовалась определенным доверительным интервалом, в котором спрогнозированный сигнал окажется с наибольшей вероятностью. Следует отметить, доверительный интервал строился на основе дисперсии последних 50 точек, поступающих на вход нейронной сети. Оценить работу нейронных сетей возможно по рисункам 4.6 – 4.11, на которых, у соответствующих компонент, входные значения (синим цветом) перетекают в спрогнозированные (фиолетовые), ограниченные вычисленной надежностью (фиолетовый цвет). В свою очередь, рисунок 4.7 повторяет рисунок 4.6, но с добавленными к нему 50 компонентами, полученными на выходе от параллельного набора цифровых ФНЧ.




Рисунок 4.6 – Экстраполяция компоненты с периодом среза 7




Рисунок 4.7 – Экстраполяция компоненты с вертикальными сигналами

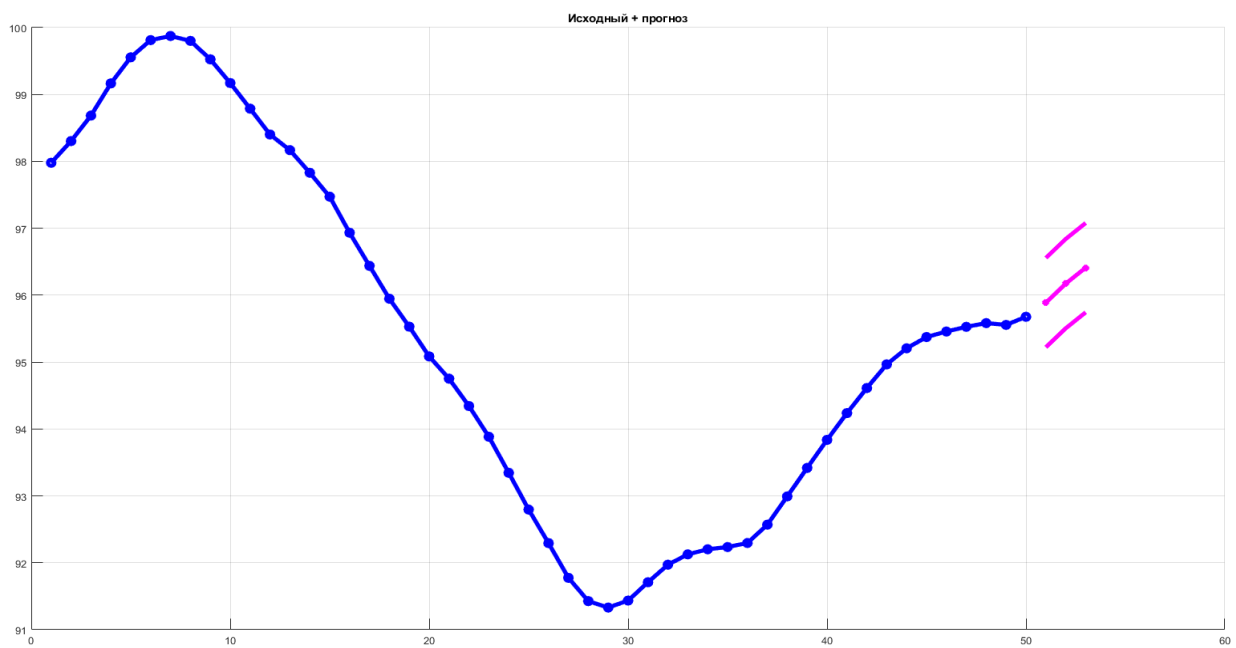


Рисунок 4.8 – Экстраполяция компоненты с периодом среза 10

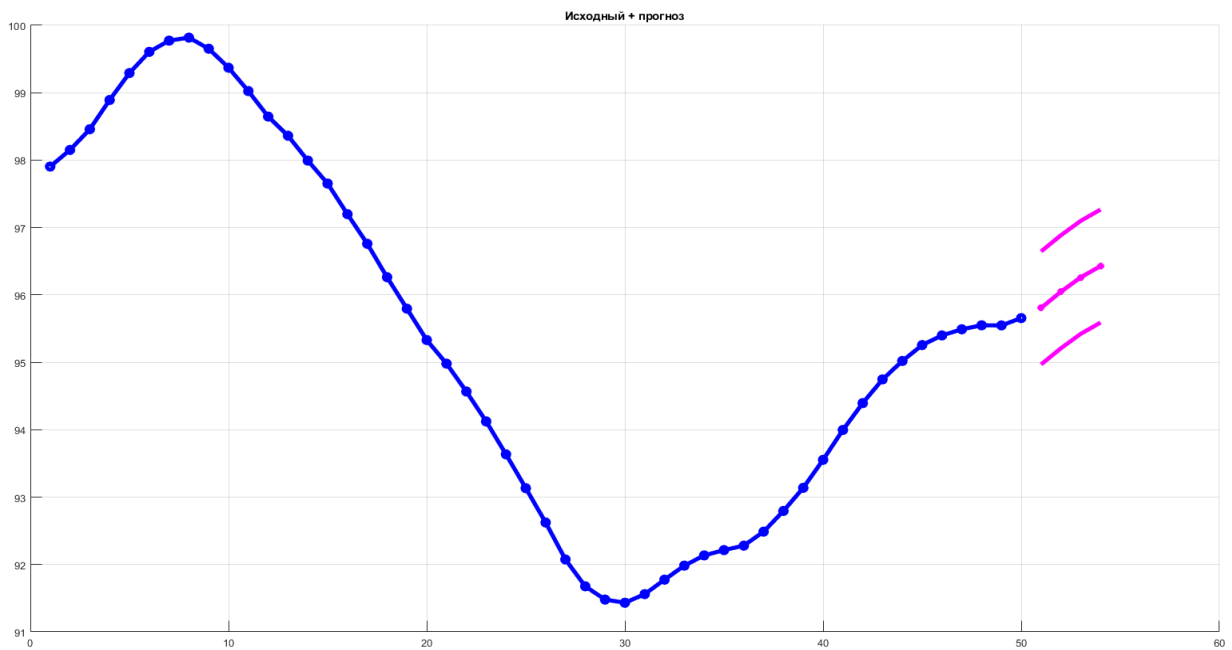


Рисунок 4.9 – Экстраполяция компоненты с периодом среза 13




Рисунок 4.10 – Экстраполяция компоненты с периодом среза 16




Рисунок 4.11 – Экстраполяция компоненты с периодом среза 19

По этим графикам видно, что в итоге прогноз существенно зависел от способа предварительной обработки входных данных и выбранный нами стабилизационный метод навязывает нейронной сети инерционные свойства. То есть проблема, поставленная вначале не наблюдается, вследствие упрощения сигналов.

Впоследствии нами осуществляется переход к заключительному этапу – объединение компонент. Объединение в систему происходило порционно из совокупности всех полученных значений на выходе, структурную схему конечного экстраполятора системы можно увидеть на рисунке 4.12.

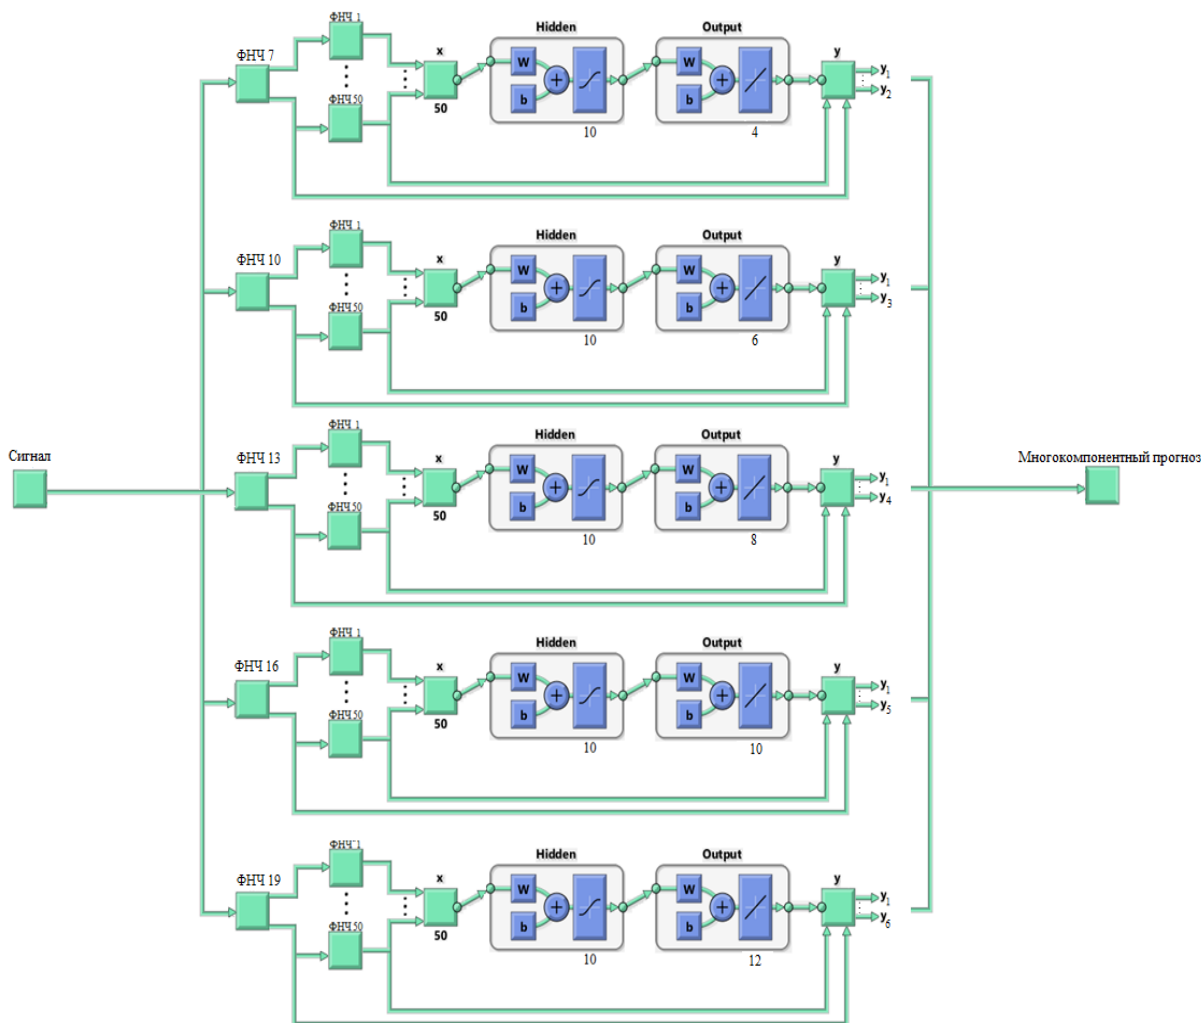


Рисунок 4.12 – Структурная схема экстраполятора

### 4.3 Пример экстраполяции многокомпонентного радиотехнического сигнала

Как указывалось выше, грация каждой составляющей такова, чем сглаженность выше, тем больше спрогнозированных значений. То есть каждый следующий сигнал имеет такое количество экстраполированных точек, которые покрывают все предыдущие. Вследствие этого, в результате отбирались по два значения спрогнозированных точек от соответствующих сигналов с шагом в одно значение. На рисунке 4.13 продемонстрирован этот случай.




Рисунок 4.13 – Многокомпонентный прогноз

Добавление целевого сигнала (черная ломаная) приведет к картине рисунок 4.14.




Рисунок 4.14 – Многокомпонентный прогноз с целевой функцией

В дополнении к приведенным рисункам необходимо продемонстрировать предыдущую картину сообразно к основополагающему сигналу (черный сигнал рисунок 4.4), для которого прогноз является продолжением, что приведено на рисунке 4.15.




Рисунок 4.15 – Многокомпонентный прогноз с историей

Рассмотренный вариант прогноза изменяется с течением времени, при получении новой реальной точки все экстраполированные величины должны быть пересчитаны и объединены в следующую версию возможного развития событий.

Достоинства разработанного экстраполятора заключаются в возможности получать точный прогноз на достаточное, но не на большое количество точек вперед. Поскольку, во-первых, необходимо было увеличивать для каждой компоненты число прогнозируемых значений что увеличило бы нагрузку на сеть и значительно отклонило бы ошибку в худшую сторону. Во-вторых, вариант использования прогноза от спрогнозированных значений означало бы нарастить ошибку в ещё большее количество раз.



## 5 Организационно-экономический раздел

В данном разделе осуществляется анализ экономической стороны проектируемого объекта, расчет эффективности данной реализации исследуемого решения и сетевое планирование разработанного нейросетевого экстраполятора.

### 5.1 Сетевое планирование

Система сетевого планирования является одной из форм научного планирования и управления в области сложных комплексов работ. ССП представляет собой особую разновидность систем организационного управления, предназначенных для регулирования и оптимизации работ по исследованию и разработки различных объектов. Также необходимо сохранить свойства системы планирования и управления, которыми являются способность оценивать текущее состояние, предсказывать дальнейший ход работ и таким образом воздействовать на ход подготовки и разработки, чтобы весь комплекс работ был выполнен в заданные сроки и с наименьшими затратами. Таким образом, должен быть построен сетевой график, содержащий все промежуточные пункты и отражающий все стороны выполнения работ, которые являются существенными в отношении достижения конечной цели.

### 5.2 Построение сетевого графика

Сетевой график представляет собой схему, на которой в определенном порядке наглядно показаны все операции (виды работ) по созданию сначала промежуточной продукции с определенной степенью готовности, а в конце – полное завершение планируемого комплекса работ (разработки), т.е. достижение конечной цели. Для построение сетевого графика необходимо определить последовательность работ, отведенное время на выполнение работ и количество исполнителей, где Р – руководитель, И-П – инженер-программист, Л – лаборант.

Ожидаемая продолжительность работы в составе сетевого графика рассчитана по двухоченочной методике, которая основывается на установленных ответственным

исполнителем минимальной и максимальной оценок продолжительности каждой работы. При условии, что минимальная оценка – это наиболее благоприятная, а максимальная оценка – неблагоприятная.

Ожидаемая продолжительность рассчитывается по формуле

$$V_{new} = V_{old} + \beta \cdot (Y - X_{old}), \quad (5.1)$$

где  $t_{ij\min}$ ,  $t_{ij\max}$  – соответственно минимальная и максимальная продолжительности выполнения работ. Продолжительности были определены эмпирическим путем во время преддипломной практики.

Среднеквадратическое отклонение  $\delta_{ij}$  продолжительности по двухоценочной методике определяется по формуле

$$\delta_{ij} = 0,2(t_{ij\max} - t_{ij\min}). \quad (5.2)$$

Также дисперсия вычисляется по формуле

$$D_{ij} = 0,04 \cdot (t_{ij\max} - t_{ij\min})^2. \quad (5.3)$$

Все вычисленные значения занесены в таблице 5.1. На рисунке 5.1 изображен сетевой график.

Таблица 5.1 – Параметры работ СГ

Код работы	Наименование работы	Продолжит., дни			Исполн.			СКО	Дисперсия
		min	max	ожид	Р	И-П	Л		
0-1	Получение темы	1	1	1	1	1	1	0	0
1-2	Актуальность темы	1	2	2	1	0	1	0,2	0,04
2-3	Анализ темы	1	3	2	1	1	0	0,4	0,16
1-4	Подбор литературы	2	4	3	0	0	1	0,4	0,16
3-5	Анализ аналогов	2	3	2	1	1	1	0,2	0,04

Продолжение таблицы 5.1

Код работы	Наименование работы	Продолжит., дни			Исполн.			СКО	Дис- персия
		min	max	ожид	Р	И-П	Л		
4-5	Утверждение ТЗ	1	2	1	1	1	1	0,2	0,04
5-6	Анализ литературы	7	10	8	1	1	0	0,6	0,36
5-7	Составление графика выполнения работ	1	2	2	1	0	1	0,2	0,04
6-8	Изучение принципов работы физ. и мат. модели нейронов	8	12	10	1	1	0	0,8	0,64
7-8	Изучение возможно- стей НС	2	4	3	1	1	0	0,4	0,16
8-9	Изучение методов разработки НС в прогр. среде	2	4	3	0	1	0	0,4	0,16
8-10	Изучение структуры и основ. функ. НС	3	4	3	1	1	0	0,2	0,04
9-12	Обоснование исполь- зования НС	2	3	2	1	1	0	0,2	0,04
10-11	Исслед. методов обуч. сети	7	10	8	1	1	0	0,6	0,36
12-13	Изуч. цифр. обр. сиг- налов	7	10	8	1	1	0	0,6	0,36
11-13	Реализация НС	1	2	2	0	1	0	0,2	0,04
13-14	Реализ. экстрап. на НС	2	4	3	0	1	0	0,4	0,16
13-15	Исслед. способов улучшения экстрапо- ляции	8	12	10	1	0	0	0,8	0,64
14-16	Разраб. методов предварит. обр. дан- ных	14	20	16	1	1	0	1,2	1,44

Продолжение таблицы 5.1

Код работы	Наименование работы	Продолжит., дни			Исполн.			СКО	Дис- персия
		min	max	ожид	Р	И-П	Л		
15-16	Исслед. разраб. ме- тодов	6	8	7	1	0	0	0,4	0,16
16-17	Конструирование экстраполятора	2	4	3	1	1	0	0,4	0,16
17-19	Тестирование экс- траполятора	10	12	11	0	1	0	0,4	0,16
17-18	Подбор лит. по БЖД	1	1	1	0	0	1	0	0
19-20	Анализ лит. БЖД	1	1	1	0	0	1	0	0
20-21	Подбор лит. по эконо- мической части	1	1	1	0	0	1	0	0
18-21	Анализ лит. по эконо- мике	1	2	1	0	0	1	0,2	0,04
21-22	Оформление ПЗ	2	3	2	0	0	1	0,2	0,04
22-23	Защита дипломной работы	1	1	1	1	1	1	0	0




Рисунок 5.1 – Сетевой график

### 5.3 Расчет параметров событий сетевого графика

Ранний срок свершения исходного (нулевого) события СГ принимается равным нулю. Ранний срок свершения данного промежуточного события рассчитывается путём сравнения сумм, состоящих из раннего срока свершения события, непосредственно предшествующего данному и длительности работы. Так как данное событие не может свершиться, пока не закончится последняя из непосредственно предшествующих ему работ, очевидно, что в качестве раннего срока свершения события принимается максимальная из сравниваемых сумм.

Рассчитанный таким способом ранний срок свершения завершающего события всего СГ принимается в качестве его же позднего срока свершения. Это означает, что завершающее событие СГ никаким резервом времени не располагает.

Поздний срок свершения данного промежуточного события определяется при просмотре СГ в обратном направлении. Для этого сопоставляются разности между поздним сроком свершения события, непосредственно следующего за данным, и продолжительности работы, соединяющей соответствующее событие с данным. Так как ни одна из непосредственно следующих за данным событием работ не может начаться, пока не свершится само данное событие, очевидно, его поздний срок свершения равен минимуму из подсчитанных разностей.

Правильность расчёта поздних сроков свершения событий СГ подтверждается получением нулевого позднего срока свершения исходного события.

Резерв времени образуется у тех событий, для которых поздний срок свершения больше раннего, и он равен их разности. Если же эти сроки равны, событие резервом времени не располагает и, следовательно, лежит на критическом пути.

Результаты расчёта сведены в таблице 5.2.

Таблица 5.2 – Параметры событий СГ

Номер события	Сроки свершения		Резерв времени
	Ранний	Поздний	
0	0	0	0
1	1	1	0
2	3	3	0
3	5	5	0
4	4	6	2
5	7	7	0
6	15	15	0
7	9	22	13
8	25	25	0
9	28	28	0
10	28	28	0
11	36	36	0
12	30	30	0
13	38	38	0
14	41	41	0
15	48	50	2
16	57	57	0

Продолжение таблицы 5.2

Номер события	Сроки свершения		Резерв времени
	Ранний	Поздний	
17	60	60	0
18	61	72	11
19	71	71	0
20	72	72	0
21	73	73	0
22	75	75	0
23	76	76	0

#### 5.4 Расчет параметров работ сетевого графика

Ранний срок начала работы  $T_{рнi}$  совпадает с ранним сроком свершения её начального события. Поздний срок начала работы  $T_{пнi}$  можно получить, если из позднего срока свершения её конечного события вычесть её ожидаемую продолжительность.

Ранний срок окончания работы  $T_{роi}$  образуется прибавлением её продолжительности к раннему сроку свершения её начального события. Поздний срок окончания работы  $T_{поi}$  совпадает с поздним сроком свершения её конечного события.

Для всех работ критического пути, как не имеющих резервов времени, ранний срок начала совпадает с поздним сроком начала, а ранний срок окончания – с поздним сроком окончания.

Работы, не лежащие на критическом пути, обладают резервами времени. Полный резерв времени работы  $R_{пi}$  образуется вычитанием из позднего срока свершения её



конечного события раннего срока свершения её начального события и её ожидаемой продолжительности. Рассчитанные значения занесены в таблице 5.3.

Таблица 5.3 – Параметры работ сетевого графика

Код работы	Ожидаемая продолжительность, дни	Сроки начала, дни		Сроки окончания, дни		Резерв времени, дни			Свободный	Коэффициент напряженности
		Ранний	Поздний	Ранний	Поздний	Полный	Частный 1-го рода	Частный 2-го рода		
0-1	1	0	0	1	1	0	0	0	0	1,00
1-2	2	1	1	3	3	0	0	0	0	1,00
2-3	2	3	3	5	5	0	0	0	0	1,00
1-4	3	1	3	4	6	2	2	0	0	0,66
3-5	2	5	5	7	7	0	0	0	0	1,00
4-5	1	4	6	5	7	2	0	2	0	0,66
5-6	8	7	7	15	15	0	0	0	0	1,00
5-7	2	7	20	9	22	13	13	0	0	0,27
6-8	10	15	15	25	25	0	0	0	0	1,00
7-8	3	9	22	12	28	13	0	13	0	0,27
8-9	3	25	25	28	28	0	0	0	0	1,00
8-10	3	25	25	28	28	0	0	0	0	1,00
9-12	2	28	28	30	30	0	0	0	0	1,00

Продолжение таблицы 5.3

Код работы	Ожидаемая продолжительность, дни	Сроки начала, дни		Сроки окончания, дни		Резерв времени, дни			Свободный	Коэффициент напряженности
		Ранний	Поздний	Ранний	Поздний	Полный	Частный 1-го рода	Частный 2-го рода		
10-11	8	28	28	36	36	0	0	0	0	1,00
12-13	8	30	30	38	38	0	0	0	0	1,00
11-13	2	36	36	38	38	0	0	0	0	1,00
13-14	3	38	38	41	41	0	0	0	0	1,00
13-15	10	38	40	48	50	2	2	0	0	0,89
14-16	16	41	41	57	57	0	0	0	0	1,00
15-16	7	48	50	55	57	2	0	2	0	0,89
16-17	3	57	57	60	60	0	0	0	0	1,00
17-19	11	60	60	71	71	0	0	0	0	1,00
17-18	1	60	71	61	72	11	7	0	0	0,15
19-20	1	71	71	72	72	0	0	0	0	1,00
20-21	1	72	72	73	73	0	0	0	0	1,00
18-21	1	61	72	62	73	11	0	11	0	0,15
21-22	2	73	73	75	75	0	0	0	0	1,00

Продолжение таблицы 5.3

Код работы	Ожидаемая продолжительность, дни	Сроки начала, дни		Сроки окончания, дни		Резерв времени, дни			Свободный	Коэффициент напряженности
		Ранний	Поздний	Ранний	Поздний	Полный	Частный 1-го рода	Частный 2-го рода		
22-23	1	75	75	76	76	0	0	0	0	1,00

5.5 Расчет стоимостных параметров научно-исследовательской работы

Для расчёта приведённой ИНЖ-численности необходимо вначале рассчитать коэффициент перерасчёта  $K_k$  численности работающих  $k$ -й категории в ИНЖ-численность, равный отношению средней заработной платы работающих  $k$ -й категории  $Z_k$  к средней заработной плате ИНЖ  $Z_{инж}$ . Должностные оклады персонала НИИ и КБ приведены в табл. 5.

Очевидно, для инженеров коэффициент перерасчёта  $k_{инж} = 1$ , для руководителей он будет больше единицы, а для лаборантов – меньше единицы. Должностные оклады приведены в таблице 5.4.

Таблица 5.4 – Оклады персонала

Категория персонала	Месячный должностной оклад, руб./мес	Количество, человек	Занятость, дни	Суммарная заработная плата, руб.
Руководитель	30000	1	87	87000
Инженер-программист	25000	1	87	72500
Лаборант	15000	1	17	8500
Итого				168000

В таблице 5.5 приведены затраты на контрагентские расходы, дополнительные материалы, программное обеспечение.

Таблица 5.5 – Дополнительные затраты

Наименование	Стоимость, руб.
Печать плакатов	2000
Печать и переплёт ПЗ	400
Бумага	300
MatLab R2015b	112000
Итого	114700

Таким образом, в итоге суммарные затраты на проведение исследовательской работы равны: 282700 рублей.

### 5.6 Экономический эффект разработки

Экономический эффект достигается за счет использования простой архитектуры искусственной нейронной сети, которая при дополнительной цифровой обработке данных позволяет сохранять и преумножать точность экстраполяции радиотехнического сигнала.

Главное достоинство – это время, затраченное на обучение искусственной нейронной сети. В сравнении со сложной архитектурой время ожидания окончания обучения возрастет в 2...3 раза. Следовательно, либо возрастет количество дней разработки, либо необходимо дополнительно закупаться оборудованием для ускорения процесса обучения.

В таблице 5.6 приведены итоговые затраты на 3 возможных варианта развития событий.

Таблица 5.6 – Анализ трех методов исследования

Вариант	Затраченное время, дни	Расходы на доп. оборудование, руб.	Итого, руб.
1	117	0	282700
2	198	0	399007
3	80	120000	349571

Таким образом, первый вариант является наиболее экономичным, т.к. расходы сокращаются как минимум на 24% по сравнению с другими методами.

## **6 Безопасность жизнедеятельности**

В данном разделе безопасности жизнедеятельности рассмотрены требования и нормы правильного взаимодействия пользователя с ПЭВМ в целях минимизации воздействия вредных факторов на человека, так как дипломная работа по построению экстраполятора полностью выполняется с использованием ПЭВМ. Выходные значения разработанного экстраполятора могут быть представлены в двух видах, а именно, на графике с возможностью приближения или в консоли программного обеспечения MatLab, таким образом, пользователь может настроить удобное для себя представление информации.

С конца 1990-х годов компьютерная индустрия приобрела интенсивный характер развития, проникнув во все сферы деятельности человек. В связи с этим, ЭВМ стали доступны многим как для домашнего использования, так и для обеспечения рабочего процесса. Однако вместе с внедрением в жизнь человека ЭВМ возник вопрос сохранения здоровья и безопасности пользователя при работе за компьютером. В настоящее время разработаны и описаны мероприятия для безопасного времяпровождения за персональным компьютером, которые в значительной степени уменьшают пагубное влияние на человека.

### **6.1 Основные негативные факторы при работе с ЭВМ**

По природе возникновения негативные факторы делятся на следующие группы:

- физические;
- химические;
- биологические;
- психофизиологические;

При работе пользователя за персональным компьютером в помещении имеют место следующие физические факторы:

- недостаточная освещенность рабочего места;
- повышенный уровень шума или вибрации;
- повышенная или пониженная температура воздуха;

- повышенная или пониженная влажность воздуха;
- и др.

К психологическим вредным факторам относят:

- умственное напряжение;
- перенапряжение зрительного аппарата;
- нервно — эмоциональные перегрузки.

При воздействии всех или некоторых факторов у пользователя может наблюдаться: снижение остроты зрения; головные боли; психические расстройства; ухудшение работы иммунитета; заболевания позвоночного отдела.

Для уменьшения пагубного влияния необходимо нормировать опасные факторы, воздействующие на человека.

Основными нормируемыми параметрами являются:

- организация рабочего места;
- освещенность рабочего места;
- значения параметров электромагнитных излучений;
- микроклимат;
- уровни шума.

## 6.2 Параметры микроклимата помещения

Для обеспечения комфортной работы человека с персональным компьютером необходимо соблюдение параметров микроклимата, которые оказывают существенное влияние на работоспособность как человека, так и ПЭВМ. Микроклимат помещений — это климат внутренней среды данных помещений, определяющийся совместно действующими на организм человека температурой воздуха, относительной влажностью и скоростью движения воздуха, а также температурой окружающих поверхностей и интенсивностью теплового облучения.

Требования к параметрам микроклимата на рабочих местах всех видов производственных помещений установлены СанПиН 2.2.4.3359-16 «Санитарно-эпидемиологические требования к физическим факторам на рабочих местах». А именно, санитар-

ные правила утверждают список гигиенических требований к параметрам микроклимата рабочих мест производственных помещений в зависимости от интенсивности энергозатрат работающих, времени выполнения работы, периодов года.

Определены оптимальные условия микроклимата по критериям оптимального теплового состояния человека. Они должны обеспечивать тепловой комфорт в течение рабочей смены при условии минимального напряжения механизмов терморегуляции, не вызывать отклонений в состоянии здоровья, создавать условия для обеспечения и сохранения высокого уровня работоспособности. Однако могут приводить к возникновению общих и локальных ощущений теплового дискомфорта, напряжению механизмов терморегуляции, ухудшению самочувствия и понижению работоспособности. Все оптимальные нормы взяты из приложений СанПиН 2.2.4.3359-16.

Для сохранения требуемых параметров микроклимата в рабочей зоне применяют механизацию и автоматизацию технологических процессов, защиту от источников теплового излучения, устройство систем вентиляции, кондиционирования воздуха и отопления.

Оптимальные нормы микроклимата в рабочей зоне для помещений приведены в таблице 6.1. Изменение температуры воздуха в помещении в течение смены должны находиться в пределах величин, указанных в таблице 6.1.

Таблица 6.1 – Оптимальные нормы микроклимата

Период года	Категория работ	Температура воздуха, гр. С	Температура поверхностей, гр. С	Относит. влажность воздуха, %	Скорость движения воздуха, м/с
Холодный	1а	22...24	21...25	40...60	0,1
	1б	21...23	20...24	40...60	0,1
Теплый	1а	23...25	22...26	40...60	0,1
	1б	22...24	21...25	40...60	0,1



Приведенные в таблице 6.1 категории работ, а именно, 1а – определяет работы, производимые сидя и не требующие физической активности, для которых потребление энергии составляет до 139 Вт; к категории 1б относятся работы, выполняемые стоя, сидя или связанные с ходьбой и сопровождающиеся некоторой физической активностью, при котором расход энергии колеблется в пределах от 140 Вт и до 174 Вт. Перечисленные категории работ полностью покрывают все виды взаимодействия с ПЭВМ.

### 6.3 Требования к уровням шума

Некоторое оборудование и дополнительные агрегаты, размещенные вблизи рабочего места, могут создавать дополнительный шум и вибрации. Высокий уровень производимого шума может приводить к ухудшению функционирования слухового аппарата.

Для уменьшения вероятности повреждения органов слуха разработаны следующие нормы, взятые из СанПиН 2.2.4.3359-16. По временным характеристикам шум подразделяется на:

- постоянный шум, уровень звука которого изменяется не более чем на 5 дБА в течение 8-часового рабочего дня;
- непостоянный шум, уровень звука которого изменяется более чем на 5 дБА в течение 8-часового рабочего дня.

В соответствии с нормами СанПиН 2.2.4.3359-16 уровень звука на рабочих местах не должен превышать 80 дБА.

Поэтому главной задачей является снижение шума, производимого на рабочих местах как внутренними источниками, так и внешними. Одним из высокоэффективных способов является использование звукопоглощающего материала для отделки помещений с максимальным коэффициентом звукопоглощения в пределах границ частот 63 ... 8000 Гц.

#### 6.4 Параметры мониторов и освещенность рабочего места

Во многих странах разработан ряд норм и документов, регламентирующих правила пользования дисплеями. СанПиН России не являются исключениями и содержат рекомендации и стандарты. А именно, СанПиН 2.2.2/2.2.4.1340-03, в котором фигурирует раздел «Требования к освещению на рабочих местах, оборудованных ПЭВМ»

Первым необходимым требованием является нормирование яркости, т.к. следует облегчить привыкание глаз к светящимся объектам. С одной стороны, пониженная освещенность помещения снижает работоспособность зрительного аппарата. Наряду с этим, падает острота зрения, скорость распознавания и идентификации объектов на дисплее и цветовое восприятие. Всё вышесказанное влечет за собой повышенное состояние психологической напряженности и усталости человека. Для обеспечения комфортных условий работы яркость монитора должна превышать 90 кд/кв. м. С другой стороны, при высоких уровнях освещенности экрана зрительный аппарат приходит в состояние утомляемости за короткий промежуток времени. Таким образом, необходимо сохранить баланс освещения в помещении. Внешние источники света следует располагать сбоку от рабочего места, параллельно линиям зрительного аппарата. Внешняя освещенность экрана должна принадлежать диапазону 100 ... 250 лк.

Также немаловажным параметром является контраст. Другими словами, контраст - это разница в характеристиках различных участков изображения. Этот параметр оказывает сильное влияние на нормальное функционирование зрения. Малый контраст делает изображение трудночитаемым. Согласно нормам, контраст не должен быть менее отношения 3:1.

Человеческий глаз в высшей степени подвержен влиянию бликов монитора и перенапряжению от распознавания мелких объектов. В связи с этим размеры объектов на экране должны быть нормированы, а поверхность экрана монитора антибликовой. Рекомендуемое минимальное расстояние от глаз до дисплея должна составлять 60 см.

Для систем, обеспечивающих освещение рабочего места, предъявляются требования: соответствие освещенности характеру выполняемых работ; равномерное распределение яркости на рабочей поверхности; отсутствие бликов и резких теней; стабильность освещения во времени; электробезопасность, пожаробезопасность.

Согласно нормам по освещению СанПиН 2.2.2/2.2.4.1340-03, предъявляют следующие требования.

- освещенность поверхности рабочего стола должна быть в пределах 300 ... 500 лк;

- допускается применение источников дополнительного местного освещения, при условии не допуска увеличения освещенности экрана не более 300 лк и отсутствие бликов;

- необходимо ограничивать источники освещения, дающие прямую блескостность, при этом, находящиеся в поле зрения объекты не должны иметь яркость более 200 кд/кв. м.

- следует правильно выбрать дополнительные светильники и их расположение на рабочем месте для исключения отраженных блескостей на рабочих поверхностях;

- следует сохранять равномерное распределение яркости в поле зрения пользователя ПЭВМ, при условии выполнения соотношения яркости между рабочими поверхностями, которое не должно превышать 3:1 ... 5:1, а между рабочими поверхностями и поверхностями стен и оборудования 10:1;

- общее освещение, осуществляющиеся за счет яркости светильников, в зоне углов излучения от 50 до 90 градусов с вертикалью в продольной и поперечной плоскостях должна составлять не более 200 кд/кв. м, защитный угол светильников должен быть не менее 40 градусов;

- светильники, применяемые для местного освещения, обязаны обладать не просвечивающим отражателем с защитным углом не менее 40 градусов;

- необходимо регулярно выполнять чистку стекол окон и светильников как минимум два раза в год для сохранения нормируемой освещенности в помещениях.

## 6.5 Параметры электромагнитных излучений

На сегодняшний день исследования о влиянии электромагнитного излучения на организм человека имеет интенсивный характер развития, т.к. человеку приходится часто сталкиваться с данным видом опасности. Поэтому работы в этом направлении исследования описывают возможные факторы риска, такие как, расстройство нервной системы, заболевания сердечно-сосудистой системы, ослабление эффективности работы иммунитета и возникновение патологии при беременности.

В таблице 6.2 приведены допустимые значения параметров излучений электромагнитных полей на рабочих местах пользователей ПЭВМ, которые установлены СанПиН 2.2.4.3359-16 «Санитарно-эпидемиологические требования к физическим факторам на рабочих местах».

Таблица 6.2 – Допустимые значения параметров излучений

Параметр	Допустимые значения
Электрическая составляющая	
5 Гц ... 2 кГц	25 В/м
2 ... 400 кГц	2,5 В/м
Магнитная составляющая	
5 Гц ... 2 кГц	250 нТл
2 ... 400 кГц	25 нТл
Плотность потока энергии	10 мкВт/см <sup>2</sup>
300 МГц ... 300 ГГц	
Напряженность электростатического поля	15 кВ/м

По причине существования строгих стандартов дозы излучения не представляют опасности для большинства пользователей за исключением людей с повышенной чувствительностью.

## 6.6 Эргономика рабочего места

Рабочее место условно означает зону, снабженная необходимым техническим средством или средствами, где работник или группа работников постоянно или временно выполняет одну работу или операцию.

Выбор правильной планировки рабочего места исключает многие неблагоприятные факторы, действующие на работающего с ПЭВМ человека.

Санитарными правилами из СанПиН 2.2.2/2.2.4.1340-03 установлены следующие нормы:

а) Рабочие столы с видеомониторами должны быть расположены друг от друга как минимум на 2 метра и расстояние между боковыми поверхностями мониторов должно быть более 1,5 м.

б) Рабочие места, оборудованные ПЭВМ, на которых производится творческая работа, сопровождающаяся умственным напряжением и высокой концентрацией внимания, рекомендуются изолировать друг от друга перегородками высотой 1,5...2,0 м.

в) Внутренняя отделка помещения с ВДТ и ПЭВМ должна состоять из диффузно-отражающих материалов с коэффициентом отражения для потолка – 0,7...0,8; для стен 0,5...0,6 и для пола 0,3...0,5.

г) Рабочий стул должен предоставлять поддержание правильной рабочей позы за ВДТ и ПЭВМ, а также позволять регулировать позу с целью уменьшения статического напряжения мышц спины и шейного отдела.

д) Экран монитора следует располагать на расстоянии 600 ... 700 мм от глаз пользователя.

е) Рабочий стол должен обеспечивать необходимое пространство для ног высотой не менее 600 мм, а шириной – более 500 мм, глубиной – не менее 450 мм.

Выполнение как минимум перечисленных норм позволит сократить влияние вредных факторов, однако существуют другие не менее важные требования.

## 6.7 Характеристики нервно-психической напряженности труда на ЭВМ

К факторам, возбуждающие нервно-психическую напряженность, можно отнести зрительные нагрузки, малоподвижная активность, монотонность выполняемых операций, вынужденная рабочая поза.

В целом большое влияние на нервно-психическую напряженность человека оказывает:

- недостаточный технический уровень используемых технологий;
- несоблюдение режима труда и отдыха, недостаточность медицинских осмотров и профилактик;
- отсутствие контроля за соблюдением норм и правил охраны труда;
- низкий уровень профессиональной подготовки сотрудников.

Для человека, непосредственно сталкивающегося с персональным компьютером, характерно временное снижение работоспособности вследствие утомления, т.е. длительной работой. Утомление сопровождается чувством слабости, отсутствием концентрации, нарушением координации движений, дефекты мышления и памяти, сонливость. Для того, чтобы исключить эти проблемы существуют категории напряженности работы с ВДТ и ПЭВМ, которые ограничивают и нормируют объем трудовой деятельности.

## 6.8 Способы и средства защиты от вредных факторов

Для уменьшения влияния вредных факторов на человека, работающего с ПЭВМ, необходим комплекс защиты, к таким относят, аппаратные средства от внешних воздействий, внутренняя защита организма, которую необходимо поддерживать и восстанавливать.

Существует совокупность индивидуальных и коллективных результативных методов защиты и профилактики:

- регулярное увлажнение и устранение пыли;
- применение спектральных очков на рабочих местах в ярких, солнечных помещениях при условии присутствия бликов на поверхностях;

- для сохранения эффективности работы иммунитета следует регулярно принимать поливитамины, бета-каротин, пищу, содержащую грубую клетчатку;
- регулярно проверять остроту зрения с помощью специальной таблицы, чтобы своевременно принять меры по лечению и профилактики зрения;
- для уменьшения зрительного и психического напряжения стоит применять аромо- и цветопротектики;
- рекомендуется во время перерыва, перед и после рабочего дня применять специальные физические упражнения и гимнастику глаз для поддержания здоровья.

Также существует множество рекомендаций и нормативов, которые сводят к минимуму отрицательное влияние компьютера на здоровье человека. При долгом времени пребывания за компьютером необходимо использовать рекомендации к комфортным для человека положениям, соответствующие эргономики, рекомендациям к регулярным паузам, которые дают отдых зрительному аппарату, снятию напряжения, утомления и усталости при выполнении простых физических упражнений.

## 6.9 Организация собственного рабочего места

Площадь помещения, в котором расположено несколько рабочих мест, составляет 18 м<sup>2</sup> изображено на рисунке 6.1.

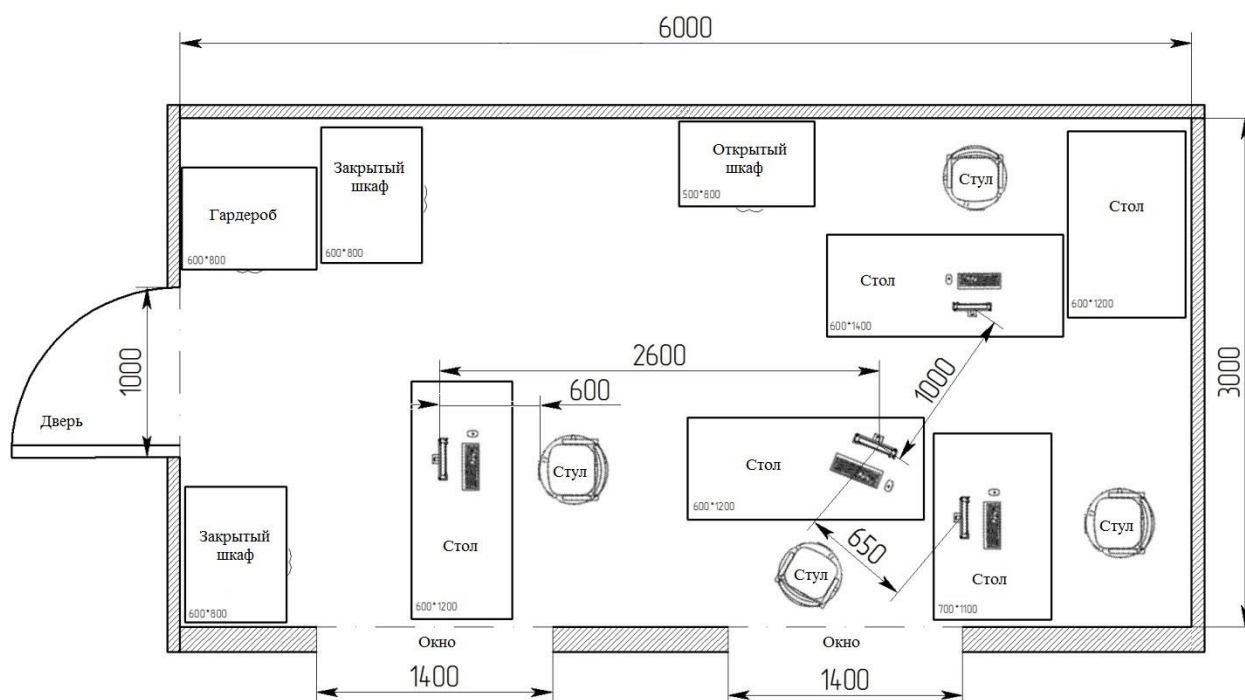


Рисунок 6.1 – Рабочее место

В данном помещении расположено 3 рабочих места с ПЭВМ, между которыми сохранены требования по размещению рабочих мест с ПЭВМ в СанПиН 2.2.2/2.4.1340-03.

В помещении присутствует естественное освещение, выполненное за счет двух окон и регулируемое жалюзи. Также присутствует искусственное освещение светодиодными лампами, расположенными параллельно окнам в три ряда, таким образом достигается равномерное освещение. На каждом столе расположены источники дополнительного света – настольные лампы.

Для поддержания оптимальной температуры помещения используется система кондиционирования воздуха – кондиционер, который сохраняет температуру рабочего помещения в комфортном диапазоне, указанном в СанПиН 2.2.4.3359-16. Проводится ежедневная влажная уборка и проветривание помещения каждый час.



Оборудование, производящее шум менее 55 дБ, такие как, принтер, сканер и сервер расположены на дополнительном столе. Их шумовой уровень не превышает нормативный, следовательно, не оказывает негативных факторов на здоровье слухового аппарата.

Используемое оборудование, такие как, мышь, клавиатура, жидкокристаллический экран расположены на рабочем столе в соответствии с эргономикой рабочего места. Расстояние от глаз и до монитора составляет 600 мм. Во избежание поражения электрическим током выполнено зануление. Высота рабочей поверхности стола составляет 755 мм. Поверхность стола имеет размеры 600 мм на 1200 мм. Стол имеют пространство для ног высотой 650 мм, шириной – 800 мм, глубиной на уровне колен – не менее 550 мм и на уровне вытянутых ног – не менее 750 мм.

Рабочее кресло работника оснащена регулировочным механизмом, позволяющим осуществлять регулирование по высоте и углам наклона сиденья и спинки, а также расстоянию спинки от переднего края сиденья, что позволяет поддерживать рациональную рабочую позу и позволяет изменять позу с целью снижения статического напряжения мышц шейно-плечевой области и спины.

Рабочее место соответствует нормам, перечисленным в: СанПиН 2.2.2/2.4.1340-03; СанПиН 2.2.4.1294-03 и СанПиН 2.2.4.3359-16.

## ЗАКЛЮЧЕНИЕ

В дипломной работе программно сконструирован нейросетевой экстраполятор, который является универсальным средством прогнозирования сложных широкополосных недетерминированных радиотехнических сигналов. Экстраполятор представляет собой программный продукт, состоящий из множества настраиваемых параметров, способный работать наравне с самыми известными моделями прогнозирования и даже во многих аспектах превосходить их. Нами проведены экспериментальные работы по выявлению эффективности работы экстраполятора при комбинировании различных внутренних параметров с использованием методов: горизонтальный, вертикальный, стабилизационный.

В ходе исследований было выявлено множество тонкостей, позволяющих улучшить как качество работы, так и минимизировать временные затраты, т.е. отклик экстраполятора, для быстрого функционирования. К самому важному шагу дипломной работы можно отнести разработку методов цифровой обработки входного сигнала, которые являются уникальными в своем роде, но при этом основываются на фундаментальных цифровых фильтрах. Разработанные методы позволили расширить возможности искусственных нейронных сетей в особенности увеличения точности экстраполяции.

На основании проделанных опытов, можно сделать следующий вывод: разделение радиотехнического сигнала сыграло ведущую роль для формирования высокоточного многокомпонентного прогноза. В результате разделения, полученные парциальные составляющие уменьшают нагрузку на нейронную сеть, тем самым расширяют предел количества спрогнозированных значений. Однако, достоинства применяемых методов не ограничивается только улучшением качества и количеством спрогнозированных точек, но и влияют на процесс обучения нейронной сети, а именно, уменьшают размер обучающей выборки, время, задействованное на обучение, и увеличивают вероятность попадания в локальный минимум, который имеет наименьшую ошибку.

Таким образом, поставленная цель – построение нейросетевого экстраполятора многокомпонентного радиотехнического сигнала достигнута, задачи исследования реализованы.

Перспективы дальнейшего исследования экстраполятора очень широки и разнообразны. Они могут положительно повлиять и дать хороший толчок на реализацию более точного прогноза радиотехнических сигналов. Дальнейшее развитие должно затронуть такие аспекты как:

а) внутренние настройки искусственной нейронной сети – например, усложнение структуры для лучшей аппроксимации обучающего сигнала, применение разнообразных функций активации у определенных нейронов, использование комбинированных методов обучения нейронной сети с целью достижения наилучшей сходимости;

б) предварительная обработка данных – например, разделение исходного сигнала на другое количество составляющих, использование гребёнки фильтров для формирования вертикального сигнала с большим шагом периода среза, дальнейшее применение различных комбинаций вертикального сигнала, задействование аналогичных цифровых фильтров для достижения наименьшего фазового сдвига и длительности переходного процесса.

Прикладной характер играет важную роль, поэтому проведенные исследования и выводы могут послужить достаточным рывком в использовании искусственных нейронных сетей для военного стратегического назначения, как к траекториям полета ЛА, так и применительно к разным радиотехническим сигналам. Однако приклад этими перечисленными направлениями не ограничивается и имеет широкий спектр направлений, при этом вопрос использования упирается в способность организовать обучающие данные таким образом, чтобы правильно обучить нейронную сеть воспринимать и экстраполировать любую последовательность данных или временных рядов.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Левин, Б.Р. Теоретические основы статистической радиотехники. 3-е изд. перераб. и доп. М.: Радио и связь, 1989. 656 с.
2. Тихонов, В.И. Статистический анализ и синтез радиотехнических устройств и систем. М.: Радио и связь, 1991. 608 с.
3. Радиолокационные системы: Основы построения и теория. Справочник / Под ред. Я.Д. Ширмана. М.: ЗАО «МАКВИС», 1998. 828 с.
4. Chen C.H., ed. Fuzzy Logic and Neural Network Handbook, NY: McGraw – Hill, 1996.
5. Zarchan P. When Bad Thing Happen To Good Missiles // Proceeding of AIAA Guidance and Control Conference, AIAA, Washington, DC, August, 1993.
6. Singhal S., Wu L. Training Multilayer Perceptron with the Extended Kalman Algorithm // Proceedings of Advances in Neural Information Processing Systems v.1, Denver, Colorado, 1988.
7. Розенблатт, Ф. Принципы нейродинамики. М.: «Мир», 1965. 468.
8. Головкин, В.А. Нейронные сети: обучение, организация и применение. М.: Радиотехника, 2001. 256 с.
9. Гоноровский, И.С. Радиотехнические цепи и сигналы. М.: Радио и связь, 1986. 512 с.
10. Медведев, В.С., Потемкин, В.Г. Нейронные сети. М.: ДИАЛОГ МИФИ, 2001. 630 с.
11. Осовский, С. Нейронные сети для обработки информации: пер. с польск. М.: Финансы и статистика, 2002. 344 с.
12. Татузов, А.Л. Нейронные сети в задачах радиолокации. М.: Радиотехника, 2009. 432 с.
13. Галушкин, А.И. Теория нейронных сетей. М.: ИПРЖР, 2000. 416 с.
14. Галушкин, А.И. Нейрокомпьютеры. М.: ИПРЖР, 2000. 532 с.
15. Гулятьев, А.К. Визуальное моделирование в среде MATLAB. СПб.: Питер, 2000. 432 с.

16. Battiti R. First and second order methods for learning: Between steepest descent and Newton's method. // *Neural Computation*. 1992. Vol. 4, N 2. P. 141–166.
17. Beale E. M. L. A derivation of conjugate gradients in F. A. Lootsma. // *Numerical methods for nonlinear optimization*. London: Academic Press, 1972.
18. Hagan M.T., Menhaj M. Training feedforward networks with the Marquardt algorithm // *IEEE Transactions on Neural Networks*. 1994. Vol. 5, N 6. P. 989–993.
19. Kohonen T. *Self-Organization and Associative Memory*. 2nd ed. Berlin: Springer-Verlag, 1987.
20. Kohonen, T. *Self-Organizing Maps, Second Edition*. Berlin: Springer-Verlag. 1997.
21. Moller M. F. A scaled conjugate gradient algorithm for fast supervised learning // *Neural Networks*. 1993. Vol. 6. P. 525-533.
22. Rumelhart D. E., Hinton G. E., Williams R. J. Learning representations by back-propagating errors // *Nature*. 1986. Vol. 323. P. 533–536.
23. Пискорский Д.С., Вдовина Н.В. Преддипломная практика и выпускная квалификационная работа для студентов специальности «Радиоэлектронные системы и комплексы»: методические указания. Челябинск: Издательский центр ЮУрГУ, 2017. – 76 с.
24. Баев Л.А., Лелекова С.Ю., Дзенлюк Н.С. Сетевые методы планирования и управления: методические указания. – Челябинск: Издательский центр ЮУрГУ, 2010. – 24 с.
25. Парубочая Т.И., Гузеев В.И. СТО ЮУрГУ 04-2008 Стандарт организации. Курсовое и дипломное проектирования. Общие требования к содержанию и оформлению. – Челябинск: Издательский центр ЮУрГУ, 2008. – 56 с.

## ПРИЛОЖЕНИЕ А

```
function One
clear;clc;

load('Fddd2','ddd2');          % Импорт из mat.файла - ddd2

rr          = size(ddd2)        % Размер импортируемого файла ddd
nmax        = rr(1);           % Максимальное количество строк в ddd
Nv          = ddd2(1:nmax,1);
Counter     = 1;              % Счетчик (Для графиков)

[T,Odine,nachalo,NumSeti,dl,Delay,Del2,Delay2,shagOp,...
 shagGT,szI,zxc,sizeIn,sizeOut,AmountNeuro,maxFail,Stabiliz,...
 Stabiliz2,novoee,novoee2,szNov,ychet,sizeOut1,shagnew,Doverit,trainG,valG,testG]=Options(Nv,nmax);% Функция настройки параметров

[in,tar,dop]=Sampling(shagGT,dl,sizeIn,sizeOut,Odine,Stabiliz2,Stabiliz,0,shagnew);% Функция формирования обучающих выборок

[In]=New(novoee,sizeIn,szNov,shagOp,dl,szI,in);% Функция оптимизации (преобр. из горизонтального в вертикальный сигнал)

[Tar]=New_1(novoee2,dl,Stabiliz2,tar,In,szNov);% Функция добавления в целевые значения стабилизаторов из вертикального сигнала

[Xs,Xi,Ai,Ts,Y]=train_1(sizeIn, sizeOut,...
 In, Tar,Delay2, AmountNeuro,NumSeti,maxFail,Delay,Del2,trainG,valG,testG);% Функция вызова обучения

[Counter]=Graphics_1(Stabiliz,Stabiliz2,dl,Del2,Ts,Y,Counter,sizeOut,Xs,novoee,sizeIn,szNov,trainG,valG,testG);% Функция отрисовки графиков для аппроксимации

[SUMMa,Xs,Xi,Ai,Ts,out,simIN,simTAR]=Forecast(szI,sizeIn,zxc,sizeOut,shagGT,...
```

```
Odine,Stabiliz2,Stabiliz,nachalo,novoee,szNov,shagOp,novoee2,NumSeti,Delay,shagnew);% Функция формирования выборок для прогноза и получения прогнозируемых точек
```

```
[Counter]=Graphics_2(Stabiliz,zxc,Del2,Ts,Counter,sizeOut,Stabiliz2,out,nachalo,szI,Odine);% Функция отрисовки графиков спрогнозированных точек
```

```
[yy,interp]=Interpolation(simIN,out,Stabiliz2,sizeOut,zxc,shagGT,Del2);% Функция получения потерянных точек (интерполяция)
```

```
[Counter]=Graphics_3(Xs,Ts,Counter,zxc,Del2,Odine,interp,nachalo,szI,yy,sizeOut,Stabiliz,Stabiliz2,shagGT,Doverit,trainG,valG,testG,dl);% Функция отрисовки спрогнозированных точек вместе с интерполированными
```

```
end
```

```
function [T,Odine,nachalo,NumSeti,dl,Delay,Del2,Delay2,...  
    shagOp,shagGT,szI,zxc,sizeIn,sizeOut,AmountNeuro,...  
    maxFail,Stabiliz,Stabiliz2,novoee,novoee2,szNov,ychet,sizeOut1,shagnew,Doverit,trainG,valG,testG]=Options(Nv,nmax)  
T = 22; % Период среза  
Odine1 = RMA_1(Nv(1:nmax,1),T); % Работа, только с одним сигналом, без SL  
Odine = Odine1(T:length(Odine1));  
Doverit = R_STD(Nv(T:length(Odine1)) - Odine,50);  
shagnew = 0; % Прореживание  
dlina = 5000; % Размер обучающей выборки  
if shagnew>=1  
    dl = round(dlina/(shagnew+1));  
else  
    dl = dlina;  
end  
  
szI = 50; % Количество входов  
nachalo = dl-szI; % С этой точки начинается прогноз  
+ sizeIn  
NumSeti = 1; % Сохр нейр. сеть  
Delay = 0; % Вкл. задержку и обратную связь  
%Чтобы менять задержку необходимо согласовать в двух последних графиках  
if Delay==1  
    % Del1=0;  
    Del2 = 1; % Задержка обратной связи (Можно изменять)  
    % Delay1=0;
```

```

    Delay2      = 0;          % Задержка входного вектора (Можно из-
менять)
else
    % Del1=0;
    Del2        = 0;
    % Delay1=0;
    Delay2      = 0;
end
shagOp         = 1;          % Шаг для вертикального сигнала
shagGT         = 1;          % Шаг для горизонтальных стабили-
заторов и шаг целей
zxc            = 3350;%635   % Кол. выборок для получения про-
гноза
sizeIn         = szI;        % Кол. входов
sizeOut        = 1;          % Кол. выходов (Количество прогнозируе-
мых точек, без стабилизаторов)
AmountNeuro    = 10;         % Кол. нейронов
maxFail        = 5;%10      % Максимальное количество ошибок на
контрольном массиве
Stabiliz       = 2; %2 %4    % Количество горизонтальных стабилиза-
торов
Stabiliz2      = 2; %2 %2    % Количество стабилизаторов из верти-
кального сигнала
повоее         = 1;          % Оптимизация, преобразование
сигнала из горизонтального в вертикальный (если 0, то кол. стаб. вер. ставить 0)
повоее2        = 1;          % Стабилизаторы из вертикального сигнала
только при оптим.(если откл., то и стабил ставить 0)
szNov          = 50;         % Кол. точек в вертикальном сиг-
нале
trainG         = 70/100;     % Часть выборок для тренировки
valG           = 15/100;     % Часть выборок для проверки
testG          = 15/100;     % Часть выборок для конечного те-
стирования
ychet          = szI-sizeIn;
sizeOut        = sizeOut+Stabiliz+Stabiliz2;
sizeOut1       = sizeOut;
end

```

```

function [in,tar,dop]=Sampling(shagGT,dl,sizeIn,sizeOut,Odine,Stabiliz2,Stabiliz,nachalo,shagnew)
in = zeros(sizeIn, dl);
tar = zeros(sizeOut, dl);
dop = shagGT;
dopNew = shagnew;
for i=1:dl
    for j=1:sizeIn
        in(j, i) = Odine(nachalo + i + j - 1 + dopNew);
%         disp('Первый')
%         nachalo + i + j - 1 + dopNew
        dopNew = dopNew + shagnew;
    end
    dopNew = dopNew - shagnew;
    for ji=1+Stabiliz2:sizeOut

```



```

        tar(ji, i) = Odine(nachalo + j + i + dop - Stabiliz*shagGT - 1 + dopNew);
%       disp('Второй')
%       nachalo + j + i + dop - Stabiliz*shagGT - 1 + dopNew
        dopNew = dopNew + shagnew;
        dop = dop + shagGT;
    end
    dopNew = shagnew;
    dop = shagGT;
end

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% save in;
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
end

```

%New Elapsed time is 36.768086 seconds.

```
function [In]=New(novoee,sizeIn,szNov,shagOp,dl,szI,in)
```

```

if novoee==1
    sizeIn = szNov;
    rut = 1;
    h = shagOp;
    for j=1:dl
        for i=3:sizeIn+1
            obmen = RMA_1(in(:,j)',2+h);
            In2(sizeIn-i+2,rut) = obmen(length(obmen));%length(obmen)-h
            clear obmen;
            h = h + shagOp;%Изм
        end
        h = shagOp;
        In2(sizeIn,rut) = in(szI,j);
        rut = rut + 1;
    end
    clear In;
    In = tonndata(In2,true,false);
else
    In=tonndata(in,true,false);
end
figure(1003);
plot(1:length(cell2mat(In)),cell2mat(In));title('Вертикальные');grid on;
% hor50 = In;
% save hor50
end

```

```
function [Tar]=New_1(novoee2,dl,Stabiliz2,tar,In,szNov)
```

```

%Стаб. из вертикальных точек
In2=cell2mat(In);
if novoee2 == 1
    dop = szNov - 1; %В обратном
%   dop = 2; %В прямом
    for i = 1:dl
        for ji = 1:Stabiliz2
            tar(Stabiliz2-ji+1, i) = In2(dop,i);

```

```

        dop = dop - 1; %В обратном
%       dop = dop + 1; %В прямом
%       dop = dop - shagOp; %Изменен шаг стабилизатора
    end
    dop = szNov - 1; %В обратном
%     dop = 2; %В прямом
    end
end

Tar = tonndata(tar,true,false);
%%%%%%%%%%%%%%
% figure(1);
% plot(1:length(In2(1:)),In2);grid on;
% save In2;
% %%%%%%%%%%%%%%%
% figure(1);
% plot(1:length(In2(1:)),In2);grid on;hold on;
% plot(1:length(in(1:)),in(300:),'bo','LineWidth',2);
end
%train Elapsed time is 106.554082 seconds.
function [Xs,Xi,Ai,Ts,Y]=train_1(sizeIn, sizeOut,...
    In, Tar,Delay2, AmountNeuro,NumSeti,maxFail,Delay,Del2,trainG,valG,testG)
[Xs,Xi,Ai,Ts]=trainO(sizeIn,sizeOut,In,Tar,Delay2,AmountNeuro,NumSeti,maxFail,De-
lay,Del2,trainG,valG,testG);
load NOVOE %При остановке вписать назввание NameNeuro...(За место многоточия ставится
число, равное периоду среза
Y = net(Xs,Xi,Ai);
%Xs = cell2mat(Xs);
%save Xs
Y = cell2mat(Y);
Ts = cell2mat(Ts);
if Delay==1
    net = closeloop(net);
end

end
%Graphics_1 Elapsed time is 11.953412 seconds.
function [Counter]=Graphics_1(Stabiliz,Stabiliz2,dl,Del2,Ts,Y,Counter,sizeOut,Xs,no-
voee,sizeIn,szNov,trainG,valG,testG)
if Stabiliz ~= 0
    figure(Counter);
    %n = max(size(Y));
    plot(1:dl-Del2, Ts(1:Stabiliz,1:dl-Del2),'k*-',1:dl-Del2, Y(1:Stabiliz,1:dl-Del2),'bo-'); %Ts - Целевые
значения, Y - аппроксимация
    title('Аппроксимация. Стабилизаторы');
    grid on;
end
Counter = Counter + 1;
figure(Counter);
%n = max(size(Y));
% Если сдвиг, то прописывать Ts(Stabiliz+1+Stabiliz2:sizeOut,1:dl-Del2-1)-Y(Stabiliz+1+Stabi-
liz2:sizeOut,1+1:dl-Del2)

```

```

disp('Error Apprx:')
t2 = sizeOut - Stabiliz2 - Stabiliz;

for i=1:t2
    Werror = abs(Ts(i+Stabiliz2+Stabiliz,:)-Y(i+Stabiliz2+Stabiliz,:));
    fprintf('Номер выхода: %i \n',i);
    werr(i) = std(Werror);
    fprintf('СКО: %i \n',werr(i));
    Maxc(i) = max(Werror);
    fprintf('Max Error = %i \n',Maxc(i));
    fprintf('Min Error = %i \n',min(Werror));
end
fprintf('СКО Mean all: %i \n',mean(werr));
fprintf('Max Mean all = %i \n',mean(Maxc));
disp('_____');

plot(1:dl-Del2, Ts(Stabiliz+1+Stabiliz2:sizeOut,1:dl-Del2),'k--',1:dl-Del2, Y(Stabiliz+1+Stabiliz2:sizeOut,1:dl-Del2),'mo-'); %Ts - Целевые значения, Y - аппроксимация
title('Аппроксимация. Прогноз');
xlim([899 1001]);
grid on;
Counter = Counter + 1;

if novoee==1
    sizeIn = szNov;
end
is = length(Y);
figure(1001); hold on; grid on;
plot(sizeIn:sizeIn + is*trainG - 1,Y(:,1:is*trainG),'k--','LineWidth',1);
plot(sizeIn + is*trainG:sizeIn + is*trainG + is*valG - 1,Y(:,is*trainG+1:is*trainG + is*valG),'b--','LineWidth',1);
plot(sizeIn + is*trainG + is*valG:sizeIn + is*trainG + is*valG + is*testG - 1,Y(:,is*trainG + is*valG + 1:is*trainG + is*valG + is*testG),'r--','LineWidth',1);
% Ошибки
plot(sizeIn:sizeIn + is*trainG - 1,Y(:,1:is*trainG) - Ts(:,1:is*trainG),'k--','LineWidth',1);
plot(sizeIn + is*trainG:sizeIn + is*trainG + is*valG - 1,Y(:,is*trainG+1:is*trainG + is*valG) - Ts(:,is*trainG+1:is*trainG + is*valG),'b--','LineWidth',1);
plot(sizeIn + is*trainG + is*valG:sizeIn + is*trainG + is*valG + is*testG - 1,Y(:,is*trainG + is*valG + 1:is*trainG + is*valG + is*testG) - Ts(:,is*trainG + is*valG + 1:is*trainG + is*valG + is*testG),'r--','LineWidth',1);
% Со сдвигом
figure(1002); hold on; grid on;
plot(sizeIn:sizeIn + is*trainG - 1,Y(:,1:is*trainG),'k--','LineWidth',1);
plot(sizeIn + is*trainG:sizeIn + is*trainG + is*valG - 1,Y(:,is*trainG+1:is*trainG + is*valG),'b--','LineWidth',1);
plot(sizeIn + is*trainG + is*valG:sizeIn + is*trainG + is*valG + is*testG - 1,Y(:,is*trainG + is*valG + 1:is*trainG + is*valG + is*testG),'r--','LineWidth',1);
% Ошибки
plot(sizeIn:sizeIn + is*trainG - 1,Y(:,1:is*trainG) - Ts(:,1:is*trainG),'k--','LineWidth',1);
plot(sizeIn + is*trainG:sizeIn + is*trainG + is*valG - 1,Y(:,is*trainG+1:is*trainG + is*valG) - Ts(:,is*trainG+1:is*trainG + is*valG),'b--','LineWidth',1);

```

```
plot(sizeIn + is*trainG + is*valG:sizeIn + is*trainG + is*valG + is*testG - 1, Y(:,is*trainG + is*valG + 1:is*trainG + is*valG + is*testG) - Ts(:,is*trainG + is*valG + 1:is*trainG + is*valG + is*testG), 'r--', 'LineWidth', 1);
```

```
end
```

```
%Forecast Elapsed time is 29.375166 seconds.
```

```
function [SUMMa,Xs,Xi,Ai,Ts,out,simIN,simTAR]=Forecast(szI,sizeIn,zxc,sizeOut,shagGT,...
```

```
Odine,Stabiliz2,Stabiliz,nachalo,novoe,szNov,shagOp,novoe2,NumSeti,Delay,shagnew)
```

```
sizeIn = szI; % Возвр значение
```

```
load NOVOE
```

```
inSim = zeros(sizeIn, zxc);
```

```
tarSim = zeros(sizeOut, zxc);
```

```
dop = shagGT;
```

```
[inSim,tarSim,dop] = Sampling(dop,zxc,sizeIn,sizeOut,Odine,Stabiliz2,Stabiliz,nachalo,shagnew);
```

```
[simIN] = New(novoe,sizeIn,szNov,shagOp,zxc,szI,inSim);
```

```
[simTAR] = New_1(novoe2,zxc,Stabiliz2,tarSim,simIN,szNov);
```

```
sizeIn = szI;
```

```
clear Xs Xi Ai Ts
```

```
if Delay==1
```

```
[Xs,Xi,Ai,Ts] = preparets(net,simIN,{ },simTAR); %%%%%%%%%%
```

```
else
```

```
[Xs,Xi,Ai,Ts] = preparets(net,simIN,simTAR); %%%%%%%%%%
```

```
end
```

```
out = net(Xs,Xi,Ai);
```

```
out = cell2mat(out);
```

```
Ts = cell2mat(Ts);
```

```
SUMMa(1:sizeOut,:) = out;
```

```
t2 = sizeOut - Stabiliz2 - Stabiliz;
```

```
disp('Error Forecast:')
```

```
for i=1:t2
```

```
Werror = abs(Ts(i + Stabiliz2 + Stabiliz,:) - out(i + Stabiliz2 + Stabiliz,:));
```

```
fprintf('Номер выхода: %i \n',i);
```

```
werr(i) = std(Werror);
```

```
fprintf('CKO: %i \n',werr(i));
```

```
Maxc(i) = max(Werror);
```

```
fprintf('Max Error = %i \n',Maxc(i));
```

```
fprintf('Min Error = %i \n',min(Werror));
```

```
end
```

```
fprintf('CKO Mean all: %i \n',mean(werr));
```

```
fprintf('Max Mean all = %i \n',mean(Maxc));
```

```
disp('_____');
```

```
end
```

```
function [Counter]=Graphics_2(Stabiliz,zxc,Del2,Ts,Counter,sizeOut,Stabiliz2,out,nachalo,szI,Odine)
```

```
%На этом графике все точки из спрогнозированных и графики целевые
```

```
if Stabiliz2 ~= 0, figure(Counter);
```

```
%n = max(size(out));
```

```
plot(1:zxc-Del2, Ts(1:Stabiliz2,1:zxc-Del2), 'k*-', 1:zxc-Del2, out(1:Stabiliz2,1:zxc-Del2), 'bo-'); % Ts -
```

```
Целевые значения, out -Вертикальные Стабилизаторы
```

```
title('Прогноз. Вертикальные стабилизаторы');
```

```
grid on;
```

```

end
Counter=Counter+1;
if Stabiliz~=0
    figure(Counter);
    %n = max(size(out));
    plot(1:zxc-Del2, Ts(Stabiliz2+1:Stabiliz2+Stabiliz,1:zxc-Del2),'k*-',1:zxc-Del2, out(Stabiliz2+1:Stabiliz2+Stabiliz,1:zxc-Del2),'mo-');%Ts - Целевые значения, out - Горизонтальные стабилизаторы
    title('Прогноз. Горизонтальные стабилизаторы');
    grid on;
    Counter=Counter+1;
end
% График, самый исходный сигнал с выхода фильтра (один) + графики всех прогнозов + графики
всех стабилизаторов
figure(Counter); hold on;
plot(1:zxc-Del2, Odine(nachalo+szI+1:nachalo+szI+1+zxc-Del2-1),'ko-', 'LineWidth',4);
if Stabiliz == 0
    plot(1:zxc-Del2, Ts(1:Stabiliz,1:zxc-Del2),'k*-',1:zxc-Del2, out(1:Stabiliz,1:zxc-Del2),'bo-');%Ts -
Целевые значения, out - Стабилизаторы
end
plot(1:zxc-Del2, Ts(Stabiliz+1:sizeOut,1:zxc-Del2),'k*-',1:zxc-Del2, out(Stabiliz+1:sizeOut,1:zxc-Del2),'mo-');%Ts - Целевые значения, out - Спрогнозированные точки
title('Исходный сигнал. Прогноз + Стабилизаторы');
grid on;
Counter = Counter + 1;
% График, самый исходный сигнал с выхода фильтра (один) + графики всех прогнозов
figure(Counter); hold on;
plot(1:zxc-Del2, Odine(nachalo+szI+1:nachalo+szI+1+zxc-Del2-1),'ko-', 'LineWidth',4);
plot(1:zxc-Del2, Ts(Stabiliz+Stabiliz2+1:sizeOut,1:zxc-Del2),'k*-',1:zxc-Del2, out(Stabiliz+Stabiliz2+1:sizeOut,1:zxc-Del2),'mo-');%Ts - Целевые значения, out - Спрогнозированные точки
title('Исходный сигнал. Прогноз');
grid on;
Counter = Counter + 1;
% График, самый исходный сигнал с выхода фильтра (один) + графики всех прогнозов
figure(Counter); hold on;
plot(1:zxc-Del2, Odine(nachalo+szI+1:nachalo+szI+1+zxc-Del2-1),'ko-', 'LineWidth',4);
plot(1:zxc-Del2, out(Stabiliz+Stabiliz2+1:sizeOut,1:zxc-Del2),'mo-');%Ts - Целевые значения, out -
Спрогнозированные точки
title('Исходный сигнал. Прогноз');
grid on;
Counter = Counter + 1;
hold off;
end
%Interpolation Elapsed time is 1.508471 seconds.
function [yy,interp]=Interpolation(simIN,out,Stabiliz2,sizeOut,zxc,shagGT,Del2)
simIN = cell2mat(simIN);
asqws = size(out(Stabiliz2+1:sizeOut,1));
interp = zeros(2*asqws(1)-1,zxc-Del2);
for WER=1:zxc-Del2
    if shagGT>=2
        x = 1:shagGT:(sizeOut-Stabiliz2-1)*shagGT+1;%Временная горизонталь, на которых располо-
жены horiz. стаб. и прогнозы
        xx = 1:1:(sizeOut-Stabiliz2-1)*shagGT+1;%Временная горизонталь для интерполяции

```

```

    y = out(Stabiliz2+1:sizeOut, WER); %Горизонтальные стабилизаторы и прогнозы
    yy = spline(x,y,xx); %Интерполяция
    interp(1:length(yy), WER) = yy(1:length(yy));
else
    yy = out(Stabiliz2+1:sizeOut, WER); %Горизонтальные стабилизаторы и прогнозы
    interp(1:length(yy), WER) = yy(1:length(yy));
end
% disp('Для продолжения нажмите Enter');
% pause % ожидание нажатия клавиши
end
end

function [Counter]=Graphics_3(Xs,Ts,Counter,zxc,Del2,Odine,interp,nachalo,szI,yy,sizeOut,Stabiliz,Stabiliz2,shagGT,Doverit,trainG,valG,testG,dl)
figure(Counter); hold on; grid on;
plot(1:length(Ts(1,:)),Ts(length(Ts(:,1))-(sizeOut-Stabiliz-Stabiliz2)*shagGT+1:1:length(Ts(:,1))),:),'k*','LineWidth',1.5);

plot(1:zxc-Del2, interp(length(yy)-(sizeOut-Stabiliz-Stabiliz2)*shagGT+1:1:length(yy),1:zxc-Del2),'mx-'); %Ts - Целевые значения, out - Спрогнозированные точки
op = 1;
for iop = nachalo-1:nachalo-1+zxc-Del2-1
    minus(:,iop) = interp(length(yy)-(sizeOut-Stabiliz-Stabiliz2)*shagGT+1:1:length(yy),iop) - Doverit(iop-Del2);
    plus(:,iop) = interp(length(yy)-(sizeOut-Stabiliz-Stabiliz2)*shagGT+1:1:length(yy),iop) + Doverit(iop-Del2);
    op = op + 1;
end
plot(1:zxc-Del2-1,minus(:,1:zxc-Del2-1),'g','LineWidth',2);
plot(1:zxc-Del2-1,plus(:,1:zxc-Del2-1),'g','LineWidth',2);
xlim([2799 2901]);

load NOVOE
proverka = 633;

net = closeloop(net);

out1 = cell2mat(net(Xs(1,proverka)));

if sizeOut>1
    plot(proverka-1,out1(sizeOut-1),'ro-',proverka,out1(sizeOut),'ro-',...
        proverka-1,Ts(sizeOut-1,proverka),'mo-',proverka,Ts(sizeOut,proverka),'mo-', 'LineWidth',4);
else
    plot(proverka,out1(sizeOut),'ro-',proverka,Ts(sizeOut,proverka),'r*-', 'LineWidth',4);
end

plot(1:zxc-Del2, interp(length(yy)-(sizeOut-Stabiliz-Stabiliz2)*shagGT+1:1:length(yy),1:zxc-Del2),'x-','LineWidth',1.15); %Ts - Целевые значения, out - Спрогнозированные точки
xlim([2799 2870]); %2860
hold off;

figure(1001);

```

```

plot(20:dl*trainG,Oline(20:dl*trainG,:),'k-', 'LineWidth',1.5);
plot(dl*trainG:dl*trainG+dl*valG,Oline(dl*trainG:dl*trainG+dl*valG,:),'b-', 'LineWidth',1.5);
plot(dl*trainG+dl*valG:dl*trainG+dl*valG+dl*testG,Oline(dl*trainG+dl*valG:dl*trainG+dl*valG+dl*te
stG,:),'r-', 'LineWidth',1.5);
plot(dl*trainG+dl*valG+dl*testG+1:dl*trainG+dl*valG+dl*testG+1 + length(interp(1,:)) - 1,in-
terp(1:sizeOut-Stabiliz2,:),'LineWidth',1.1);
plot(dl*trainG+dl*valG+dl*testG+1:dl*trainG+dl*valG+dl*testG+1 + length(interp(1,:)) - 1,in-
terp(1:sizeOut-Stabiliz2,:) - Ts(Stabiliz2+1:sizeOut,:),'LineWidth',1.1);
hold off;
% Со сдвигом
figure(1002);
plot(20+1:dl*trainG+1,Oline(20:dl*trainG,:),'k-', 'LineWidth',1.5);
plot(dl*trainG+1:dl*trainG+dl*valG+1,Oline(dl*trainG:dl*trainG+dl*valG,:),'b-', 'LineWidth',1.5);
plot(dl*trainG+dl*valG+1:dl*trainG+dl*valG+dl*testG+1,Oline(dl*trainG+dl*valG:dl*trainG+dl*valG
+dl*testG,:),'r-', 'LineWidth',1.5);
plot(dl*trainG+dl*valG+dl*testG+1:dl*trainG+dl*valG+dl*testG+1 + length(interp(1,:)) - 1,in-
terp(1:sizeOut-Stabiliz2,:),'LineWidth',1.1);
plot(dl*trainG+dl*valG+dl*testG+1:dl*trainG+dl*valG+dl*testG+1 + length(interp(1,:)) - 1,in-
terp(1:sizeOut-Stabiliz2,:) - Ts(Stabiliz2+1:sizeOut,:),'LineWidth',1.1);
hold off;
end

```

```

function [Xs,Xi,Ai,Ts] = trainO(sizeIn,sizeOut,In,Tar,Delay2,AmountNeuro,NumSeti,maxFail,De-
lay,Del2,trainG,valG,testG)

```

```

if Delay==1
    net = narxnet(Delay2,Del2,AmountNeuro);
else
    net = timedelaynet(0:0,AmountNeuro);
end
net.inputs{1}.size = sizeIn;
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
net.layers{1}.initFcn = 'initnw';
net.layers{1}.transferFcn = 'tansig';%%%%%%purelin
net.layers{2}.size = sizeOut;
net.outputs{2}.processFcns = {'removeconstantrows','mapminmax'};
net.layers{2}.transferFcn = 'purelin';
if Delay==1
    [Xs,Xi,Ai,Ts] = preparets(net,In,{},Tar);
else
    [Xs,Xi,Ai,Ts] = preparets(net,In,Tar);
end
%tempo = cell2mat(Xs);
%save tempo
net.divideFcn = 'dividerand';
net.divideMode = 'value';
net.divideParam.trainRatio = trainG; % Часть выборок для тренировки
net.divideParam.valRatio = valG; % Часть выборок для проверки
net.divideParam.testRatio = testG; % Часть выборок для конечного тестирования
net.performFcn = 'mse'; % Функция оценки качества
net.trainFcn = 'trainlm'; % Функция тренировки trainlm traingda trainscg

net.trainParam.epochs = 5000; % Максимальное количество эпох тренировки

```

```

net.trainParam.goal = 0;           % Допустимая погрешность (Условие остановки по отклонению
от эталона)
net.trainParam.max_fail = maxFail; % Максимальное количество ошибок на контрольном мас-
сиве
net.trainParam.min_grad = 1e-20;   % Минимальный градиент
net.trainParam.mu = 0.7;           % Начальное значение mu
net.trainParam.mu_dec = 0.1;       % Коэффициент убывания mu
net.trainParam.mu_inc = 1.45;      % Коэффициент возрастания mu
net.trainParam.mu_max = 1e10;      % Максимальное значение mu
net.trainParam.show = 25;          % Количество эпох между графиками

```

```

net.trainParam.showCommandLine = false;
net.trainParam.showWindow = true;
net.trainParam.time = inf;
%'useParallel','yes','useGPU','only'
net = train(net,Xs,Ts,Xi,Ai,'useParallel','yes','showResources','yes');%'useParallel' 'useGPU'
save NOVOE net           %При остановке вписать название NameNeuro...(За место многоточия ста-
вится число, равное периоду среза)
end

```

```

function rezfltr = RMA_1(ddd,T)

```

```

if T == 0 || T == 1
    rezfltr=ddd;
else
    Nk=T;
    Nk=2*(Nk-ceil(Nk/2)) + 1;
    Tz=floor(Nk/2); TD=fix(Tz);
    %1 -один
    for i=1:Nk
        k1 = (i-(Nk+1)/2);
        k = k1 + TD;
        if k == 0
            w(i) = 1;
        else
            w(i) = sin(2*pi*k/T)/(2*pi*k/T);
        end
        if (1-(4*k/T)^2) == 0
            wa(i) = w(i)*pi/4;
        else
            wa(i) = w(i)*cos(2*pi*k/T)/(1-(4*k/T)^2);
        end
        ww(i) = wa(i)*exp(-0.5*(1.8*k1/((Nk-1)/2))^2);
    end
    w=ww/sum(ww);
    rezfltr=filter(w,1,ddd);
end

```

```

end
function mdcd = R_STD(dd1,N)

```

```

nmax=max(size(dd1));

```



```
mdcd(1:N,1)=zeros(N,1);
for i=N+1:nmax
    cd=std((dd1(i-N:i))');
    mdcd(i-N,1)=cd;
% СКО от 1000 значений и запись начинается с 1001 ячейки в mdcd
end
end
```