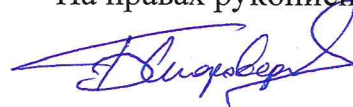


Федеральное государственное автономное образовательное учреждение высшего образования «Омский государственный технический университет»

На правах рукописи



СТАРОВЕРОВ Борислав Алексеевич

**Теоретическое обоснование и практическая реализация систем
прогнозирования электропотребления на основе ансамблей нейронных сетей
в масштабе региональной сетевой компании**

Специальность 2.3.1 – Системный анализ, управление и
обработка информации, статистика

ДИССЕРТАЦИЯ

диссертации на соискание учёной степени
кандидата технических наук

Научный руководитель:
Доктор технических наук, профессор
Хамитов Рустам Нуриманович

ОМСК 2023

ВВЕДЕНИЕ.....	4
ГЛАВА 1. СУЩЕСТВУЮЩИЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ, ИХ ОЦЕНКА И ЗАДАЧИ ИССЛЕДОВАНИЯ.....	13
1.1. Структура технического и коммерческого учета электроэнергии с подсистемой прогнозирования	13
1.2. Укрупненная классификация видов прогнозирования	15
1.3. Теоретическая основа регрессионных и нейросетевых моделей прогнозирования.....	18
1.4. Обоснование концепции формирования ансамблей нейронных сетей минимальной структуры.....	24
1.5. Выводы по главе 1.....	29
ГЛАВА 2. СИНТЕЗ ЭФФЕКТИВНЫХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ КАК ОСНОВА ПОСТРОЕНИЯ АНСАМБЛЕЙ ДЛЯ СИСТЕМ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ	32
2.1. Оценка аппроксимирующих возможностей нейронных сетей	32
2.2. Определение состава входных векторов	39
2.3. Обоснование структуры эффективных нейронных сетей	47
2.4. Методики обучения нейронных сетей для прогнозирования электропотребления	52
2.5. Анализ и синтез базисных типов нейронных сетей	55
2.6. Выводы по главе 2.....	66
ГЛАВА 3. МЕТОДИКА ФОРМИРОВАНИЯ АНСАМБЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ СИСТЕМ ПРОГНОЗИРОВАНИЯ	71
3.1. Принципы работы и классификация ансамблей нейронных сетей	71
3.2. Методика формирования ансамбля из эффективных нейронных сетей	77
3.3. Метод выбора нейронных сетей для формирования системы прогнозирования в виде ансамбля.....	80
3.4. Методика формирования ансамблей на основе взаимной компенсации погрешностей прогнозирования	87

3.5. Разработка алгоритма процессов отбора нейронных сетей и формирования ансамблей.....	94
3.6. Выводы по главе 3.....	99
ГЛАВА 4. ПРАКТИЧЕСКАЯ РЕАЛИЗАЦИЯ СИСТЕМ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ.....	102
4.1. Применение систем прогнозирования для управления экономической эффективностью закупки, передачи и распределения электрической энергии ...	103
4.2. Схемы применения систем прогнозирования для диспетчерского управления электрическими сетями.....	107
4.3. Практическая реализация системы прогнозирования в составе диспетчерского управления	110
4.4. Разработка программного обеспечения и практические результаты применения разработанных методов и средств	114
4.5. Выводы по главе 4.....	119
ЗАКЛЮЧЕНИЕ	122
СПИСОК ЛИТЕРАТУРЫ	125
ПРИЛОЖЕНИЕ 1	136
ПРИЛОЖЕНИЕ 2.....	139
ПРИЛОЖЕНИЕ 3.....	147

ВВЕДЕНИЕ

Актуальность темы исследования и степень ее разработанности.

Одними из основных направлений развития систем управления на современном этапе являются «цифровизация» и «интеллектуализация», т.е. применение методов искусственного интеллекта. Это относится также к такой важной области хозяйственно-экономической деятельности как энергетика. С каждым годом растет роль распределенной генерации, развиваются «смарт» технологии, такие как «умные сети», «умный город». В таких условиях для эффективного управления процессами электроснабжения необходимо не только оперативно реагировать на изменения нагрузки в сети, но и с максимальной возможной точностью их прогнозировать и действовать на упреждение.

Повышение эффективности выполнения функций технологического и диспетчерского управления на границах ответственности региональной сетевой компании и на отдельных ее участках также связано с необходимостью использования не только ретроспективной и текущей информации об электропотреблении, но и прогнозных данных. Сюда относятся задачи по расчету режимов нагрузки сетей, расчету потерь электроэнергии, формированию планов отключения и подключения потребителей, определению графиков ремонтных работ и т.д. В техническом плане с точки зрения автоматизации процессов управления режимами работы электрических сетей включение подсистем прогнозирования электропотребления в информационно-измерительные системы учета электроэнергии значительно расширяет их функциональные возможности и повышает эффективность.

Многоплановость технико-экономических задач функционирования региональных электросетевых компаний и работающих с ними в тесном взаимодействии электросбытовых компаний также требует применять прогнозирование электропотребления на различную перспективу. Для операций по покупке и продаже электроэнергии на федеральном оптовом рынке электроэнергии и мощности (ФОРЭМ) необходимы системы краткосрочного прогнозирования. Для

оптимизации распределения нагрузки между производителями и потребителями электроэнергии требуются системы среднесрочного прогнозирования. Расчет тарифов, перспективное планирование и управление развитием энергетических компаний базируется на системах долгосрочного прогнозирования.

В связи с важностью прогнозирования электропотребления для хозяйственно-экономической деятельности за последние десятилетия появилось большое количество исследований на эту тему, в результате которых был разработан ряд оригинальных методов и практических решений. Список авторов работ включает десятки имен: Б.И. Макоклюев, Т.А. Филиппова, И.И. Надтока, А.В. Гофман, А.С. Ведерников, И.Ю. Алексеева, К.Л. Соломахо, И.А. Чучуева и т.д. Такое количество и разнообразие работ по исследуемой проблеме обусловлены рядом причин: различные условия и факторы, определяющие потребление электроэнергии, различные виды прогнозов, разнообразные методы и средства получения прогнозов.

В то же время применение этих решений ограничено рядом причин. Во-первых, это уникальность моделей и методик, выражающаяся в том, что они хорошо работают для определенных условий и масштабов электропотребления и видов потребителей, а при других условиях требуется заново проводить процедуру адаптации. Во-вторых, необходима, как правило, ручная корректировка получаемых прогнозов. Поэтому на данный момент для прогнозирования потребления электроэнергии используются в основном инженерно-аналитические команды специалистов и даже специализированные центры. Такая технология имеет широкое распространение, но она не отвечает современному уровню как с экономической точки зрения – высокая цена прогнозирования, так и с содержательной – возможность субъективных ошибок в процессе анализа.

Развитие компьютерных технологий, значительное повышение вычислительных мощностей, наличие высокоскоростных каналов связи, появление цифровых подстанций, развитие теории систем искусственного интеллекта позволяют вывести решение задач прогнозирования потребления электроэнергии на новый уровень, расширить область применения систем прогнозирования в

масштабах региональной сетевой компании для управления экономической эффективностью закупки и распределения электрической энергии для совершенствования принятия решений в системах технологического и диспетчерского управления электросетями.

Таким образом, создание высокоточных систем прогнозирования электропотребления, применимых к различным графикам нагрузки и видам прогнозов остается актуальной проблемой.

Объектом исследования являются системы краткосрочного, среднесрочного и долгосрочного прогнозирования электропотребления в масштабах региональной сетевой компании на основании данных, получаемых от средств технического и коммерческого учета электроэнергии.

Предметом исследования являются методы, модели и алгоритмы прогнозирования, и их практической реализации в составе систем управления электропотреблением.

Область исследования. Работа выполнена в соответствии с пунктами Паспорта научной специальности 05.13.01 – «Системный анализ, управление и обработка информации» (в соответствии с новой номенклатурой научных специальностей 2.3.1 – Системный анализ, управление и обработка информации, статистика), пунктом 4 – «Разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений и обработки информации» и пунктом 10 – «Методы и алгоритмы интеллектуальной поддержки при принятии управленческих решений в технических системах» и пунктом 11 – «Методы и алгоритмы прогнозирования и оценки эффективности, качества и надежности сложных систем».

Целью диссертационной работы является разработка методов и средств повышения универсальности и точности прогнозирования электропотребления, применимых к различным типам графиков нагрузки и видам прогнозов в масштабах региональной электросетевой компании для систем предиктивного (прогнозного) диспетчерского управления и технико-экономического планирования.

Задачи исследования:

1. Оценить существующие методы и средства прогнозирования потребления электроэнергии с позиции применимости для систем с расширенными возможностями по получению различных видов прогнозов.
2. Обосновать концепцию интеграции аппроксимирующих возможностей нейронных сетей путем их объединения в ансамбль как способ повышения точности и универсальности систем прогнозирования электропотребления.
3. Провести анализ и синтез наиболее эффективных нейронных сетей, т.е. имеющих минимально возможные погрешности аппроксимации, как основы для построения ансамблей.
4. Разработать методику синтеза и алгоритмы формирования ансамблей из эффективных нейронных сетей.
5. Осуществить практическую реализацию систем прогнозирования электропотребления и применение их для решения задач технико-экономического и диспетчерского управления в масштабах региональной электросетевой компании.

Методы исследования. Для решения поставленных задач были использованы следующие методы: теория систем и системный анализ, теория вероятности, регрессионный и корреляционный анализ, теория систем искусственного интеллекта, теория автоматического управления. Для реализации систем прогнозирования использован язык C#, для работы с нейронными сетями – библиотека Fast Artificial Neural Network (FANN).

Научная новизна заключается в разработке теоретической основы построения систем прогнозирования электропотребления в виде ансамбля искусственных нейронных сетей, а именно:

1. Разработана оригинальная концепция построения ансамбля, имеющего иерархическую структуру и отличающаяся тем, что ансамбль формируется из эффективных нейронных сетей, выходные сигналы нижнего уровня (метаданные) которых используются для обучения нейросетей следующего уровня, которые, в свою очередь, реализуют мета алгоритм, компенсирующий погрешности прогнозов

отдельных нейросетей. Благодаря этому осуществляется управляемое глубокое обучение на ограниченном множестве ретроспективных данных, что обеспечивает повышение точности прогнозирования и универсальности по отношению к видам прогнозов электропотребления.

2. Обоснована методика синтеза эффективных нейронных сетей, отличающаяся тем, что:

- оценка аппроксимирующих возможностей нейронных сетей осуществляется с помощью полученных выражений функциональной связи между входными и выходными переменными сети, благодаря чему определено, что необходимо, как минимум, применение трехслойной структуры нейросетевых моделей с нелинейными функциями активации;

- определение состава динамических переменных входных векторов для краткосрочного, среднесрочного и долгосрочного прогнозирования осуществляется методом авторегрессионной аппроксимацией ретроспективных данных, получаемых от средств технического учета электроэнергии, что позволяет формировать минимальные по размерности входные векторы;

- синтез структур эффективных нейронных сетей производится путем определения соотношения между объемом обучающей выборки и числом настраиваемых коэффициентов, которые отличаются тем, что в результате избыточного числа нейронов в скрытых слоях обеспечивается применимость их к графикам потребления электроэнергии различной конфигурации.

3. Разработана методика синтеза ансамблей в соответствии с предложенной концепцией из эффективных нейронных сетей в виде иерархической структуры типа стэкинга, отличающаяся тем, что нейронные сети для ансамбля отбираются на основе попарного сравнения по двум критериям: по критерию, определяющему минимальную корреляцию графиков прогнозирования отдельных нейросетей и по критерию максимально возможной компенсации взаимной погрешности этих прогнозов.

Практическая значимость работы состоит в следующем:

1. Получена структура системы технического и коммерческого учета электроэнергии с расширенными функциональными возможностями, которые обеспечиваются подсистемой прогнозирования за счет чего появляются новые возможности: «предсказания» загрузки электросетей и реализация упреждающего управления.

2. Определен состав входных векторов, типы, структуры и технология обучения наиболее эффективных нейронных сетей, имеющих минимально возможные погрешности аппроксимации, как для самостоятельного использования, так и в составе ансамблей.

3. Сформированы ансамбли нейронных сетей для систем краткосрочного и среднесрочного прогнозирования электропотребления, обеспечивающих уменьшение величин погрешностей прогнозирования на 20-80% по сравнению с одиночными нейронными сетями.

4. Разработаны алгоритмы отбора эффективных нейронных сетей и формирования ансамблей на их основе, а также программное обеспечение, реализующее эти алгоритмы, с использованием библиотеки искусственных нейронных сетей Fast Artificial Neural Network (FANN), имеющие необходимый набор нейронных сетей и сервисных функций, которые позволяют автоматизировать процессы синтеза системы для различных видов прогнозирования электропотребления.

5. Разработан алгоритм принятия решений на основе использования систем прогнозирования при покупке и продаже электроэнергии на ФОРЭМ.

6. Установлены взаимосвязи между иерархическими уровнями АИИС КУЭ и функциями системы поддержки принятия управленческих решений на основе прогнозирования электропотребления, что позволяет строить интеллектуальные информационно-измерительные системы необходимого масштаба и интегрировать их с другими подсистемами АСУ электросетей.

Достоверность научных результатов и положений определяется применением широко используемых и апробированных методов решения научных задач, корректностью применения математического анализа и математических

выводов, методов теории машинного обучения и моделирования, а также обоснованной методикой постановки экспериментов, отбора и обработки экспериментальных данных, сходимостью теоретических выводов и экспериментальных результатов.

Положения, выносимые на защиту:

1. Концепция формирования и методика синтеза ансамбля в виде многоуровневой иерархической структуры, формируемой из эффективных нейронных сетей для повышения универсальности и точности систем прогнозирования.

2. Методики синтеза эффективных нейронных сетей, применимых к различным видам прогнозов и графикам потребления электроэнергии, и формирования из них ансамблей для уменьшения погрешностей прогнозирования.

3. Алгоритмы автоматизации процессов синтеза эффективных нейронных сетей и ансамблей на их основе, а также программное обеспечение, реализующее эти алгоритмы.

4. Структура взаимосвязей между иерархическими уровнями АИИС УЭ и системами поддержки принятия управленческих решений с использованием прогнозов электропотребления.

Практическое использование результатов работы.

Системы прогнозирования были испытаны и внедрены в производственные процессы в Костромской энергосбытовой компании, в Филиале МРСК центра – Костромаэнерго, в ООО «Старк», г. Москва, инновационный центр «Сколково», в ООО «РСМ-системы», г. Москва. Полученные результаты показали высокую эффективность применения в диспетчерском управлении и расчетах тарифов на электроэнергию, что подтверждено актами внедрения результатов диссертационной работы.

Теоретические и экспериментальные результаты используются также в учебных курсах магистерской и аспирантской подготовки.

Совокупность полученных результатов исследования является решением актуальной научной проблемы, направленной на совершенствование систем

прогнозирования для технико-экономического планирования развития региональной сетевой компании и для диспетчерского управления распределительными электросетями.

Разработан программный продукт для отбора нейронных сетей для формирования ансамбля прогнозирования электропотребления (свидетельство о регистрации №25191).

Разработан программный продукт для прогнозирования энергопотребления «Смартэнергопрогноз» в среде C# (свидетельство о регистрации № 25192).

Связь работы с научными программами, планами, темами, грантами.

Исследование выполнено в рамках государственного задания Министерства науки и высшего образования РФ (тема: «Предиктивное управление потоками энергии электрогенерирующих комплексов Арктики и Крайнего Севера, при стохастических характерах потребления и генерации электрической энергии: теория, синтез, эксперимент», код темы: FENG-2023-0001).

Апробация работы и публикации.

Основные результаты диссертационного исследования докладывались и обсуждались на XXVIII Международной научной интернет-конференции «Математические методы в технике и технологиях» (г. Ярославль), XVIII Всероссийской научно-технической конференции «Нейроинформатика-2016» (г. Москва), научно-технических конкурсах «Энергопрорыв-2016» и «Энергопрорыв-2017» (г. Москва), треке «Power and Energy» акселератора «Generation-S» 2016 (г. Иркутск), Всероссийской научно-практической конференции с международным участием "Актуальные вопросы энергетики" 2023г. (г. Омск).

По теме диссертации опубликовано 12 работ, в том числе 6 в изданиях, рекомендованных ВАК России для публикации результатов кандидатских диссертаций и 1 статья в зарубежном издании, индексируемом в SCOPUS.

Соискатель Староверов Б.А. переименовал фамилию Гнатюк Борислав Алексеевич и стал Староверовым Бориславом Алексеевичем (Свидетельство о перемене имени И-ФО № 506174 от 17.09.2017 г.).

Структура и объем диссертации.

Диссертационная работа состоит из введения, четырех глав, заключения, списка используемых источников, включающего 119 наименований, трёх приложений. Работа изложена на 156 страницах машинописного текста, содержит 34 рисунка и 19 таблиц.

ГЛАВА 1. СУЩЕСТВУЮЩИЕ МЕТОДЫ ПРОГНОЗИРОВАНИЯ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ, ИХ ОЦЕНКА И ЗАДАЧИ ИССЛЕДОВАНИЯ

Технической основой для прогнозирования потребления электроэнергии является автоматизированная информационно-измерительная система учета электроэнергии (АИИС УЭ). Под этим определением понимается функционально объединённые информационно-измерительные комплексы учета потребления электроэнергии. АИИС УЭ по своему назначению подразделяются на автоматизированные информационно-измерительные системы коммерческого учета электроэнергии (АИИС КУЭ) и автоматизированные информационно-измерительные системы технического учета электроэнергии (АИИС ТУЭ) [1,2]. Другим общепринятым является сокращенное название – автоматизированные системы технического или коммерческого учета электроэнергии (АСТУЭ или АСКУЭ). В дальнейшем оба эти определения будут использоваться равноправно.

1.1. Структура технического и коммерческого учета электроэнергии с подсистемой прогнозирования

Данные, получаемые с помощью АИИС УЭ, используются на уровне технологического и диспетчерского управления, планирования и коррекции текущих режимов энергосистемы, для коммерческого и технического учета электроэнергии. Одновременность процессов производства и потребления электрической энергии обуславливает необходимость одновременного измерения производимой, передаваемой и потребляемой энергии и мощности, а также выработки технических, организационных и экономических мер по оптимизации режимов работы энергосистем, по выравниванию графиков нагрузки. Для выполнения этих функций управления необходима информация не только о текущем и прошлом потреблении электроэнергии, но и информация о перспективных или прогнозных графиках нагрузки.

Как правило, процессы измерения или учета электропотребления и процессы прогнозирования организационно и технически разъединены. Очевидно, объединение этих процессов может дать дополнительный эффект при

технологическом и диспетчерском управлении передачей и распределением электроэнергии, что требует расширения функций автоматизированных систем учета электроэнергии. Технически это целесообразно реализовать, используя принцип объединения подсистемы измерения и подсистемы прогнозирования. За счет этого у АСКУЭ появляется новое интеллектуальное свойство – возможность «предсказания» состояния электросетей и обеспечения упреждающего управления. На Рис.1.1 в обобщенном виде представлена структура автоматизированной интеллектуальной системы технического и коммерческого учета электроэнергии (АИСКУЭ), расширение функциональных возможностей которой обеспечивается подсистемой прогнозирования [3].

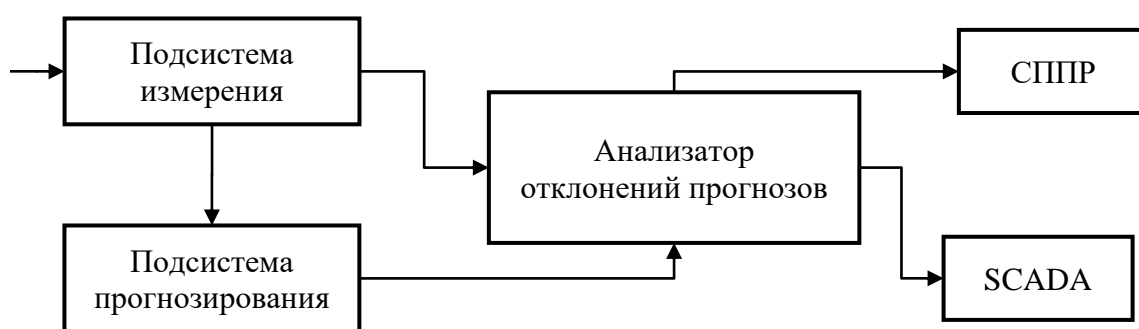


Рис.1.1. Структура АИСКУЭ с подсистемой

Сигналы с первичных измерителей (ПИ) поступают в подсистему измерения, которая выполняет основные функции АСКУЭ. Выходная информация с этой подсистемы поступает на вход подсистемы прогнозирования выработки и потребления энергии и на вход анализатора отклонений прогнозов от показателей измерения. С анализатора и с подсистемы измерения информация поступает на систему поддержки принятия решений СППР и SCADA. Информация с этих блоков может быть использована для целей упреждающего управления производством, передачей и сбытом электроэнергии.

Технические средства измерения количества, качества электроэнергии и мощности достаточно хорошо разработаны и используются с самого начала создания и развития сетей электроснабжения. Более того, эти средства постоянно улучшаются и модернизируются в соответствии с общим развитием науки и техники. Например, в настоящее время, осуществляется переход к

микропроцессорным системам обработки информации [4]. Наиболее сложной задачей является реализация систем прогнозирования. В настоящее время для этих целей существует множество методик и программных средств. Однако все они требуют предварительной адаптации под конкретные условия режимов работы энергических объектов. Анализ существующих теоретических и практических разработок в этой области показал наличие их большого разнообразия при определенной бессистемности. Потому, первоочередной задачей является классификация видов, методов и моделей прогнозирования.

1.2. Укрупненная классификация видов прогнозирования

Для оценки различных видов и методов получения прогнозов потребления электроэнергии проведем их классификацию. На способы прогнозирования влияют: масштаб охвата и вид потребителей; область применения или назначение прогнозов; временные интервалы, на которые распространяются прогнозы; модели и методы, применяемые для осуществления прогнозов (Рис.1.2).

По масштабу охвата прогнозирование осуществляется в диапазоне от районных и объединённых диспетчерских управлений в целом по объединенной энергосистеме для согласования генерируемой и потребляемой электроэнергии и мощности до отдельных предприятий, микрорайонов и жилых домов для решения задач энергосбережения и выравнивания графиков электропотребления [5-14].



Рис.1.2. Укрупненная классификация условий прогнозирования

По виду, потребителей можно выделить промышленных, которые в свою очередь различаются по отраслям, мелко-моторных, бытовых, доля потребления электроэнергии которыми в последние десятилетия постоянно увеличивается [7].

От этого зависит набор тех факторов, которые необходимы для обеспечения требуемой точности прогнозирования. Например, в масштабе региона значимыми являются такие факторы, как время года (зима, лето), тип дня (рабочий, выходной) и т.д. В отличие от прогноза в масштабе предприятия, при котором наиболее важны такие факторы, как вид технологических циклов, режим работы предприятия.

По временным интервалам потребления также имеется большое количество видов прогнозирования. Например, для балансировки генерируемой и потребляемой электроэнергии и мощности в масштабах ОДУ и для выбора состава включенного генерирующего оборудования – от 2 до 9 суток вперед; на 2 суток вперед – для расчета предварительных энергетических режимов; на 1 сутки вперед – для прогнозирования электропотребления диспетчерского графика; на текущие сутки – для расчетов планов балансирующего рынка электроэнергии [8].

В работах, посвященных проблемам прогнозирования, временные диапазоны классифицируются различными способами: в течение одних суток – оперативный прогноз; на сутки-неделю-месяц вперед – краткосрочный прогноз; на месяц-квартал-год – долгосрочный прогноз [9]. Применяются также другие градации: очень краткосрочный прогноз (от нескольких секунд до часа вперед); краткосрочный прогноз (от часа до недели вперед); среднесрочный прогноз (от недели до года вперед); долгосрочный прогноз (от года до 20 лет вперед) [10]. В работе [11] предложено использование только двух градаций: интервал времени от предстоящих суток до недели – краткосрочное прогнозирование, от месяца до года – долгосрочное. Из этого следует, что не существует точной классификации прогнозирования по временным периодам [12,13].

В данной работе используется следующая классификация:

- оперативное прогнозирование (на час вперед);
- краткосрочное прогнозирование (на сутки вперед);
- среднесрочное прогнозирование (на неделю, на месяц вперед).
- долгосрочное прогнозирование (на квартал, на год вперед).

При всех видах прогнозирования решаются задачи как на определение перспективных усреднённых показателей – среднесуточное, среднемесячное

потребление, так и детализированных – почасовой прогноз на сутки вперёд, ежедневное на неделю вперед и т.д. Например, одним из основных требований к среднесрочному прогнозированию является возможность учета посуточных колебаний внутри месяца, т.к. данный тип прогнозирования применяется для различных задач контроля и управления.

Рассмотрим более детально классификацию прогнозирования по областям применения, моделям и методам.

Классификация методов прогнозирования потребления электроэнергии с позиции особенностей методов и моделей представлена на Рис.1.3.



Рис.1.3. Классификация прогнозирования по методам и моделям

Экспертный метод прогнозирования основан на опыте и интуиции. Различают индивидуальные и групповые методы прогнозирования [14]. Наиболее подробно разработаны групповые методы экспертиз [15,16]. Данные методы применяются в тех случаях, когда прогноз не представляет больших сложностей и наоборот, когда прогнозирование связано с необходимостью учета большого количества факторов и случайных процессов. Он широко распространен в сбытовых и сетевых компаниях, т.к. существующие аналитические методы чаще всего не могут обеспечить требуемую точность прогнозирования. Недостатком таких методов является наличие субъективных факторов, влияющих на качество прогноза и затратность, т.к. для их реализации необходим постоянно действующий штат экспертов.

Сценарные модели и методы во многом схожи с экспертными технологиями прогнозирования. Отличие состоит в том, что в этом случае прогноз базируется на

оценке перспектив технического и социального развития, рассматриваемого круга потребителей от отдельных предприятий до крупномасштабного региона. В связи с этим сценарное прогнозирование носит технико-экономический характер и применяется для планирования на длительную перспективу (долгосрочное прогнозирование).

Экстраполяционные модели и методы прогнозирования базируются на основе расчёта прогнозируемых показателей как продолжения динамического ряда по выявленной закономерности развития. Таким образом, экстраполяция является переносом тенденций и закономерностей прошлого на будущее с учетом взаимосвязей показателей одного ряда. Этот метод требует предварительной обработки исходного числового ряда с целью снижения влияния случайной составляющей и субъективных ошибок [15].

Регрессионные методы как разновидность экстраполяционных методов используют для решения задач прогнозирования путем выявления зависимостей между прогнозируемой переменной и ретроспективными данными и внешними факторами или регрессорами. С этой целью чаще всего используются методы наименьших квадратов или максимального подобия для определения коэффициентов регрессии [10]. Методы, основанные на регрессионных моделях, обладают простотой, гибкостью и сравнительно высокой скоростью работы. Рассмотрим эти модели более подробно.

1.3. Теоретическая основа регрессионных и нейросетевых моделей прогнозирования

Так как прогнозирование электропотребления тесно связано с решением задач прогнозирования поведения временных рядов, то для этих целей часто используется авторегрессионный метод [17-22]. В основе прогноза с помощью авторегрессионного анализа лежит выражение:

$$\hat{y}(n) = w_1 y(n-1) + w_2 y(n-2) + \dots + w_k y(n-k) + \varepsilon(n), \quad (1.1)$$

где: $\hat{y}(n)$ – прогнозируемое значение,

$y(n-1), \dots, y(n-k)$ – ретроспективные значения временного ряда, используемые для прогнозирования,

w_1, \dots, w_k – коэффициенты веса составляющих временного ряда,
 $\varepsilon(n)$ – ошибка прогнозирования.

В матрично-векторной форме уравнение (1.1) будет иметь вид:

$$\hat{y}(n) = \mathbf{W}^T \mathbf{Y}(n-1) + \varepsilon(n) = \mathbf{Y}^T(n-1) \mathbf{W} + \varepsilon(n) \quad (1.2)$$

где $\mathbf{W}^T = [w_1 w_2 \dots w_k]$,

$\mathbf{Y}^T(n-1) = [y(n-1) y(n-2) \dots y(n-k)]$.

При увеличении горизонта прогнозирования временной ряд дополняется прогнозными значениями, полученными на предыдущих шагах:

$$\hat{y}(n+l) = w_{l-1} y(n-l-1) + w_{l-2} y(n-l-2) + \dots + w_k y(n-k) + \varepsilon(n+l) \quad (1.3)$$

где l – количество шагов (интервалов) прогнозирования. Очевидно, что должно соблюдаться условие $l < k$.

Оптимальное значение коэффициентов в авторегрессии (1.1) определяется методом наименьших квадратов [57], суть которого состоит в следующем.

Определяется среднеквадратичная ошибка:

$$E\{e^2(n)\} = \frac{1}{2} E\{y(n) - \mathbf{W}^T \mathbf{Y}(n)\}^2 \quad (1.4)$$

Далее для определения оптимальных, в смысле минимума среднеквадратичной ошибки, коэффициентов авторегрессии берутся частные производные от среднеквадратичной ошибки (1.4) по искомым коэффициентам регрессии и приравниваются к нулю:

$$\frac{\partial e^2(n)}{\partial \mathbf{W}^T} = -E\{y(n) - \mathbf{W}^T \mathbf{Y}(n)\} \mathbf{Y}^T(n) = 0 \quad (1.5)$$

Полагая, что весовой вектор \mathbf{W}^T не коррелирован с вектором $\mathbf{Y}(n)$, из (1.5) получается, что

$$E\{y(n) \mathbf{Y}^T(n)\} = E\{\mathbf{W}^T \mathbf{Y}^T(n) \mathbf{Y}(n)\}. \quad (1.6)$$

Члены математического ожидания, входящие в (1.6), представляют:

$\mathbf{P} = y(n) \mathbf{Y}(n)$ – взаимную корреляцию между входным сигналом и оцениваемым параметром;

$\mathbf{R} = \mathbf{Y}(n) \mathbf{Y}^T(n)$ – автокорреляционную матрицу входной сигнальной последовательности.

Следовательно, выражение (1.6) приобретает вид:

$$\mathbf{P}^T = \mathbf{W}^T_{opt} \mathbf{R} \quad (1.7)$$

Уравнение (1.7) является уравнением Винера – Хопфа [22], которое дает оптимальное (по методу наименьших квадратов) решение для \mathbf{W} :

$$\mathbf{W}^T_{opt} = \mathbf{R}^{-1} \mathbf{P} \quad (1.8)$$

Возможность определения оптимальных коэффициентов веса связано с необходимостью знания автокорреляционной \mathbf{R} матрицы и матрицы взаимной корреляции \mathbf{P} , входящих в выражение (1.8), что на практике часто не осуществимо.

Другой способ, в котором используется «пакетный способ» для экстраполяции (прогнозирования) временного ряда методом наименьших квадратов, основан на выборке (отрезке) значений временного ряда, максимально подобной выборке (отрезку), непосредственно предшествующей моменту прогноза [23, 24]. Алгоритм реализации этого метода, включающий метод перебора определения длины выборки и момента, предшествующего максимально подобной выборке подробно представлен в [21]. В случае прогнозирования потребления электроэнергии выбор подобных интервалов достаточно очевиден и, тем не менее, данная технология является довольно громоздкой и требует эмпирического подтверждения своей состоятельности для каждого временного ряда, имеющего, как правило, свою специфику.

Более эффективным является определение весовых коэффициентов авторегрессии итерационным методом. В алгоритмических методах расчета получили наибольшее распространение рекурсивный алгоритм наименьших квадратов (РНК) или рекуррентный метод наименьших квадратов (РМК) [25]. Реализовать эти методы можно также путем использования простейшей линейной нейронной сети [26], которая имеет такую же структуру в соответствии с выражением (1.1), как и фильтр на Рис.1.4, коэффициенты которого настраиваются в соответствии с вариациями среды. Под средой понимается пространство множества значений, генерируемое динамической системой с неизвестными параметрами через равные промежутки времени.

Или

$$\begin{bmatrix} y(n) \\ y(n-1) \\ \dots \\ y(n-p) \end{bmatrix} = \begin{bmatrix} y(n-1) & y(n-2) & \dots & y(n-k) \\ y(n-2) & y(n-3) & \dots & y(n-k-1) \\ \dots & \dots & \dots & \dots \\ y(n-p-1) & y(n-p-2) & \dots & y(n-p-k) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \dots \\ w_k \end{bmatrix} + \begin{bmatrix} \varepsilon(n) \\ \varepsilon(n-1) \\ \dots \\ \varepsilon(n-p) \end{bmatrix}.$$

При $p > k$. оптимальное значение коэффициентов для такой переопределенной системы по минимуму наименьших квадратов при прямом решении в пакетном режиме, исходя из (1.8), определяется выражением:

$$\widehat{\mathbf{W}}(n) = [\mathbf{Y}(n)^T \mathbf{Y}(n)]^{-1} \mathbf{Y}(n)^T \mathbf{y}(n) \quad (1.9)$$

Непосредственное использование выражения (1.9) связано с большими вычислительными проблемами. Поэтому используются итерационные методы определения коэффициентов регрессии. Так как определение весовых коэффициентов осуществляется путем минимизации среднеквадратической ошибки:

$$\mathbf{E}(\mathbf{W}) = 0,5 \mathbf{e}^2(n),$$

где $e(n) = y(n) - \hat{y}(n) = y(n) - \mathbf{Y}^T(n) \mathbf{W}$, то частные производные по весовым коэффициентам в векторной форме представляется следующим выражением:

$$\frac{\partial \mathbf{E}(\mathbf{W})}{\partial \mathbf{W}} = -\mathbf{e}(n) \frac{\partial \mathbf{e}(n)}{\partial \mathbf{W}}.$$

учитывая, что

$$\frac{\partial \mathbf{e}(n)}{\partial \mathbf{W}} = -\mathbf{Y}(n),$$

получается:

$$\frac{\partial \mathbf{E}(\mathbf{W})}{\partial \mathbf{W}} = -\mathbf{Y}(n) \mathbf{e}(n)$$

Использования этой зависимости в качестве градиента определения весовых коэффициентов методом наискорейшего спуска по минимуму наименьших квадратов (MLS) определяет итерационный алгоритм следующего вида:

$$\widehat{\mathbf{W}}(n+1) = \mathbf{W}(n) + \eta \mathbf{Y}(n) \mathbf{e}(n),$$

где η – скорость обучения.

Таким образом, нейронная сеть, представленная на Рис.1.4, по существу, реализует методику прогнозирования на основе линейной авторегрессии, т.к. ее

функционирование описывается уравнением (1.1), а синаптические коэффициенты так же, как и весовые коэффициенты в регрессионном анализе определяются по минимуму наименьших квадратов при обучении сети методом обратного распространения ошибки [26].

При использовании линейной нейронной сети упрощается определение размера входного вектора (число k) проведением численных экспериментов, а число p ограничивается лишь объемом обучающей выборки. В то же время получать прогнозы с требуемой точностью с помощью линейной нейронной сети весьма проблематично. Необходимо использовать более сложные нейронные сети, которые осуществляют нелинейную аппроксимацию.

Благодаря указанным свойствам широкое развитие получили в 80-х годах прошлого века и в настоящее время наиболее часто используются в задачах краткосрочного прогнозирования модели и методы на основе искусственных нейронных сетей (ИНС) [26-31].

Их применение обуславливается рядом факторов:

- появление высокоэффективных программных продуктов, которые предоставляют возможность использовать большое количество типов нейронных сетей для проведения прогнозирования на основе классификации (кластеризации) и аппроксимации (интерполяции и экстраполяции);
- разработано большое количество технологий прогнозирования с помощью нейронных сетей и накоплен опыт применения в различных областях;
- применение ИНС позволяет учесть множество факторов и автоматически определять их непосредственное и опосредованное влияние на прогнозируемый процесс;
- благодаря перечисленным причинам с помощью ИНС имеется возможность осуществлять прогнозирование с помощью сложных, нелинейных самоадаптируемых моделей.

Однако методы на основе ИНС имеют ряд существенных недостатков:

- во-первых, не существует формальных методов по определению набора значимых факторов, используемых для прогнозирования;

– во-вторых, отсутствуют правила выбора типов и структур нейронных сетей, наиболее адекватно соответствующих виду и характеру прогнозируемого процесса;

– в-третьих, не существует однозначных рекомендаций по выбору технологий обучения ИНС, требуемого объема исходных данных, глубины ретроспективы и её связи с горизонтами планирования, однозначного решения проблемы переобучения и недообучения (насыщения) нейронных сетей.

Все эти вопросы решаются, как правило, эвристическим, экспериментальным путем. Таким образом, методики прогнозирования на основе ИНС занимают промежуточное положение между экспертными и аналитическими методами. Этим объясняется большое количество работ, посвященных прогнозированию с помощью ИНС. С одной стороны, сравнительно просто, благодаря имеющимся пакетам программ, осуществлять прогнозирование на основе ретроспективных данных. С другой стороны, полученные модели и методы являются уникальными и требуется существенная корректировка при их применении для других периодов, видов и масштабов потребителей.

1.4. Обоснование концепции формирования ансамблей нейронных сетей минимальной структуры

Нейронной сети способны, в принципе, аппроксимировать функции от многих переменных с минимальной (в пределе с нулевой) погрешностью. Это требует значительного увеличения количества нейронов в составе сети, что, в свою очередь, требует большого объема обучающих выборок. Хотя в ряде работ доказано [32,33], что нейронные многослойные сети при ограниченном числе нейронов могут обеспечить уменьшение погрешности аппроксимации до приемлемых величин, однако применение таких многослойных нейронных сетей значительно усложняет процедуру их обучения и также требуется большой объем обучающей выборки. Практика показывает, ретроспективные данные старше двух лет при краткосрочном прогнозировании являются не актуальными, т.е. объем ретроспективных данных для прогнозирования почасового потребления не

превосходит 18 тысяч отсчетов. Вследствие чего возникает проблема обеспечения необходимой точности прогнозирования.

Как уже отмечалось, несмотря на адаптивность, масштабируемость и способность учитывать нелинейные зависимости, в общем случае, модели на основе одиночных ИНС не обладают необходимой универсальностью по отношению к видам прогнозов и особенностям графиков потребления электроэнергии. Поэтому на сегодняшний день данные задачи не решены, т.к. анализ работ по прогнозированию потребления электроэнергии показал, что в основном, они базируются на системах с одиночными нейросетевыми моделями.

В связи с этим выдвигается гипотеза, что лишь объединение различных типов нейронных сетей в ансамбли или комитеты позволит решить задачи обеспечения требуемой точности для различных видов прогнозов и графиков потребления электроэнергии.

Как правило, ансамбли нейронных сетей применяется в тех случаях, когда требуется решить задачи классификации и регрессии для больших объемов данных (100 тысяч и более примеров) [34,35]. При этом ансамбли формируются из, так называемых, «слабых» нейронных сетей, т.е. нейронных сетей, имеющих точность для заданной плотности распределения данных, незначительно превосходит угадывание. Они имеют простую архитектуру и быстро обучаются. Идеологическая основа построения таких ансамблей базируется на центральной предельной теореме теории вероятности [36,37]. Эта теорема определяет, что последовательности частичных средних, подчиняющихся нормальному распределению, вычисленные по наборам из n независимых случайных величин, имеющих большую дисперсию σ , стремятся к нормальному распределению:

$$f(x_{\text{ср}}) = \frac{\sqrt{n}}{\sigma\sqrt{2\pi}} e^{-\frac{n}{2\sigma^2}(x-\mu)^2} \quad (1.10)$$

Следовательно, если использовать результаты прогнозов множества нейронных сетей путем их усреднения, то можно получить результирующее среднеквадратическое отклонение в \sqrt{n} раз меньше. То есть, при определенных условиях, среднее от значений прогнозов отдельных моделей окажется ниже

неопределенности отдельной модели. Поэтому, чем больше число нейронных сетей, выходные сигналы которых усредняются, тем получается более высокая точность. Однако с ростом n уменьшение среднеквадратического отклонения растет медленно, поэтому количество сетей берется в пределах от 100 до 500. При этом необходимо обеспечить статистическую независимость ошибок прогнозов отдельных нейронных сетей. Для этого применяются различные способы: обучение нейросетей производится на разных выборках или (и) используются различные их модели. Но это опять требует большого объема обучающей выборки. Поэтому, в связи с тем, что при прогнозировании электропотребления объем обучающих выборок ограничен, стоит задача повысить точность прогнозирования с помощью применения ансамбля или комитета, но формируемого из ограниченного по архитектуре и числу нейронных сетей. Эту задачу можно решить при обеспечении двух условий:

- использовать наиболее эффективные, т.е. имеющие минимально возможные погрешности аппроксимации, нейронные сети;
- обеспечить статистическую независимость прогнозируемых результатов каждой из нейронных сетей.

Так как нейронные сети обучаются на одной и той же выборке ретроспективных данных, необходимо использовать различные виды сетей. Тем не менее, на ограниченном наборе нейросетей полную статистическую независимость реализовать практически невозможно. Следовательно, путем нахождения средней величины результатов прогнозов отдельных нейросетей добиться уменьшения дисперсии результирующего прогноза, как это предлагается в некоторых исследованиях [38], является проблематичным.

Более перспективным методом является применение взвешенного суммирования:

$$\hat{y}_R(\hat{y}) = \frac{1}{n} \sum_{i=1}^n a_i \hat{y}_i(\mathbf{x}) + b, \quad (1.11)$$

где $\hat{y}_i(\mathbf{x})$ – выходной сигнал с i -той нейросети; $\hat{y}_R(\hat{y})$ – результирующий прогноз;

$\hat{\mathbf{y}}$ – вектор прогнозов отдельных нейронных сетей первого уровня;

a_i – текущий весовой коэффициент.

В этом случае дисперсия результирующего сигнала (прогноза) будет определяться выражением:

$$\sigma_R^2 = \frac{1}{n} \left(\sum_{i=1}^n a_i^2 \sigma_i^2 + 2 \sum_{i < j} a_i a_j r_{ij} \sigma_i \sigma_j \right), \quad (1.12)$$

где r_{ij} – коэффициент корреляции между выходными сигналами с i -той и j -той нейронными сетями.

Из (1.12) следует, что непосредственное определение весовых коэффициентов не представляется возможным из-за большого количества априори неизвестных параметров. Если $r_{ij} = 0$, то получим результат, совпадающий с выводами из (1.10): $\sigma_R = \frac{\sigma_i}{\sqrt{n}}$.

Реально выходные сигналы с i - и j -той нейросетей коррелированы. Поэтому определение весовых коэффициентов является самостоятельной задачей. Предлагается для получения результирующего прогноза с меньшей дисперсией, чем у прогнозов, отдельных нейронных сетей первого уровня ансамбля, использовать многоуровневую аппроксимацию. Для этого необходимо использовать, как и для получения оценок $\hat{y}_i(\mathbf{x})$, нейронную сеть, входной вектор которой формируется из $\hat{y}_i(\mathbf{x})$, $i = 1, 2, \dots, n$ выходных сигналов нейронных сетей первого уровня ансамбля для k -тых моментов времени, а за обучающие величины принимаются истинные значения энергопотребления в эти моменты – y_k . В итоге обучение нейронных сетей второго уровня будет иметь выходные сигналы:

$$\hat{y}_{Rj}(\hat{\mathbf{y}}_k) = y_k + \varepsilon_k \quad (1.13)$$

Из (1.12) также следует, что дисперсия результирующего сигнала выходных сигналов нейронных сетей второго уровня в значительной мере зависит от корреляции входных сигналов сетей первого уровня. Поэтому необходима специальная операция по отбору таких эффективных сетей, выходные сигналы которых будут взаимно компенсировать погрешности аппроксимации. Для

определения условий такой компенсации можно использовать теорему Байеса [36,39]:

$$P(O_i|П_j) = \frac{P(П_j|O_i)P(O)}{P(П)},$$

где $P(O_i|П_j)$ – условная вероятность отрицательной погрешности i -той нейронной сети ($e_i(\mathbf{x}) = y(\mathbf{x}) - \hat{y}_i(\mathbf{x}) < 0$) на k -том шаге прогнозирования при положительной погрешности j -той нейронной сети ($e_j(\mathbf{x}) = y(\mathbf{x}) - \hat{y}_j(\mathbf{x}) > 0$) на том же шаге;

$P(П_j|O_i)$ – условная вероятность положительной погрешности j -той нейронной сети при отрицательной погрешности i -той нейронной сети;

$P(П)$ и $P(O)$ – вероятности появления положительных и отрицательных погрешностей.

В идеальном случае для полной взаимной компенсации погрешностей необходимо равенство $P(O_i|П_j) = P(П_j|O_i)$ при $P(П) = P(O)$, что практически маловероятно. Поэтому необходима разработка специального алгоритма по отбору эффективных нейронных сетей, выходные сигналы которых минимально коррелированы при максимально возможной компенсации взаимной погрешности прогнозов.

Очевидно, что для дальнейшего уменьшения дисперсии погрешности прогнозирования можно сформировать из обученных нейронных сетей также третий уровень, который будет осуществлять аппроксимацию результатов прогнозирования нейронных сетей второго уровня. Но при этом необходимо учитывать, что взаимная корреляция входных переменных при переходе от одного уровня к другому будет возрастать. Это накладывает ограничение на количество уровней ансамбля.

Таким образом, на основании анализа аппроксимирующих возможностей нейронных сетей для уменьшения дисперсии погрешностей прогнозирования энергопотребления предлагается следующая концепция формирования ансамбля.

Ансамбль должен иметь многоуровневую иерархическую структуру, формируемую из эффективных нейронных сетей, отобранных таким образом, что выходные сигналы нейросетей нижнего уровня, на которых обучаются нейросети следующего уровня, имели минимальную корреляцию и обеспечивали максимально возможную взаимную компенсацию погрешности отдельных прогнозов с помощью этой нейросети.

1.5. Выводы по главе 1

1. Предложена структура системы технического и коммерческого учета электроэнергии, заключающаяся в объединении подсистемы измерения и подсистемы прогнозирования. За счет этого у информационно-измерительных систем появляется новое интеллектуальное свойство – возможность «предсказания» состояния электросетей для обеспечения упреждающего управления на уровне технологического и диспетчерского управления.

2. Определены условия, влияющие на выбор способов прогнозирования: масштаб охвата и вид потребителей; область применения и назначение прогнозов; временные интервалы, на которые распространяются прогнозы; модели и методы прогнозирования. По временным интервалам прогнозов принята следующая классификация: оперативное, краткосрочное, среднесрочное и долгосрочное прогнозирование. Оперативные и краткосрочные прогнозы являются основой диспетчерских графиков, формируемых на период от часа до суток вперед; среднесрочные прогнозы требуются для расчета стоимости потребляемой электроэнергии и формирования режимов работы распределительных сетей; сводные долгосрочные прогнозы необходимы для составления общих ежегодных балансов.

3. На основе анализа литературных источников осуществлена классификация моделей и методов прогнозирования потребления электроэнергии по укрупненным группам, а именно: экспертный (интуитивный); сценарный; экстраполяционный. Наиболее распространенными и перспективными являются экстраполяционные методы, использующие регрессионные и нейросетевые модели прогнозирования.

4. Проведенные исследования показали, что регрессионные модели, базирующихся на рекурсивных или рекуррентных методах наименьших квадратов, а также родственных им моделях, использующих методы максимального подобия, и линейные нейронные сети, обучаемые методом обратного распространения по минимуму наименьших квадратов, имеют общую теоретическую основу. При этом нейросетевые модели обладают значительными преимуществами благодаря возможности учета множества факторов, влияющих на потребление электроэнергии, а также определения их непосредственного и опосредованного влияния на прогнозируемый процесс, способности к обучению и обобщению, т.е. к адаптации к различным видам прогнозируемых процессов. В то же время получать прогнозы с требуемой точностью с помощью линейной нейронной сети весьма проблематично. Необходимо использовать более сложные нейронные сети, которые осуществляют нелинейную аппроксимацию.

5. Несмотря на адаптивность, масштабируемость и способность учитывать нелинейные зависимости модели на основе одиночных нейронных сетей не обладают необходимой универсальностью по отношению к видам прогнозов и особенностям графиков потребления электроэнергии. В связи с этим выдвинута гипотеза, что лишь объединение различных типов нейронных сетей в ансамбли позволит решить задачи обеспечения требуемой точности для различных видов прогнозов и графиков потребления электроэнергии.

6. Ансамбли нейронных сетей, как правило, применяется в тех случаях, когда требуется решить задачи классификации и регрессии для больших объемов данных. При этом ансамбли формируются из, так называемых, «слабых» нейронных сетей.

7. В связи с ограниченным объемом обучающих выборок проведена оценка возможной статистической зависимости прогнозов отдельных нейросетей и разработана оригинальная концепция построения систем прогнозирования электропотребления в виде ансамбля, который бы обеспечивал за счет многоуровневой аппроксимации уменьшение результирующей погрешности.

8. Установлено, что ансамбль должен иметь иерархическую структуру, формируемую из эффективных нейронных сетей, обученных таким образом, что выходные сигналы нейросетей нижнего уровня (метаданных) имели минимальную корреляцию и обеспечивали максимально возможную взаимную компенсацию погрешности отдельных прогнозов. Компенсация осуществляется с помощью нейронной сети следующего уровня, обученной в качестве мета алгоритма на выборке выходных сигналов предыдущего уровня.

ГЛАВА 2. СИНТЕЗ ЭФФЕКТИВНЫХ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ КАК ОСНОВА ПОСТРОЕНИЯ АНСАМБЛЕЙ ДЛЯ СИСТЕМ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ

2.1. Оценка аппроксимирующих возможностей нейронных сетей

Для синтеза эффективных нейронных сетей и формирования ансамблей необходимо оценить их аппроксимирующие возможности.

Как уже подчёркивалось в предыдущем разделе, чтобы получать прогнозы с требуемой точностью, необходимо использовать более сложные нейронные сети, которые осуществляют нелинейную аппроксимацию. В связи с этим рассмотрим такую двухуровневую нейронную сеть с прямым распространением, которая представлена на Рис.2.1.

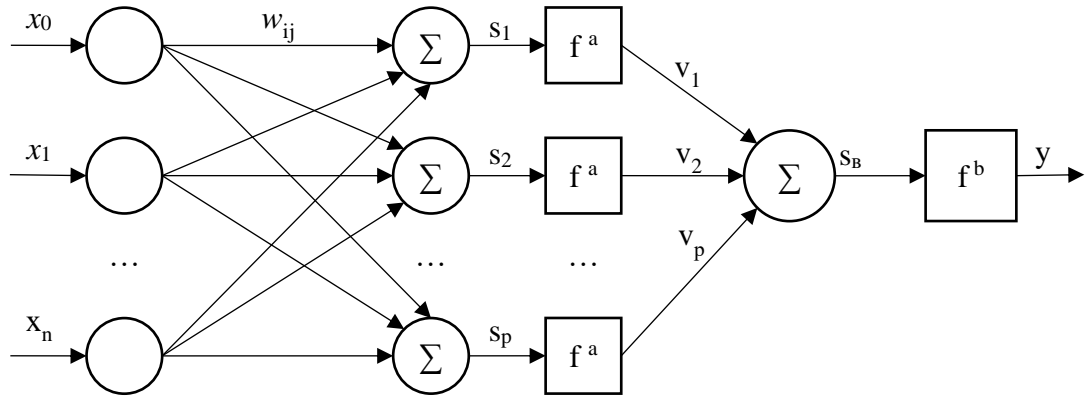


Рис.2.1 Структура двухуровневой нейронной сети с прямым распространением

На Рис.2.1 приняты следующие обозначения:

x_0 – сигнал для смещения разделяющей гиперплоскости;

x_1, \dots, x_n – входные сигналы, y – выходной сигнал;

$w_{i,j}$ и v_j – весовые коэффициенты синаптических связей между нейронами;

f^a – функция активации нейронов скрытого слоя;

f^b – функция активации выходного нейрона.

По аналогии с линейной нейронной сетью (см. Рис.1.4), сигналы с нейронов промежуточного слоя, которые подаются на функции активации, определяются выражением:

$$\begin{bmatrix} w_{11} & w_{21} & \dots & w_{n1} \\ w_{12} & w_{22} & \dots & w_{n2} \\ \dots & \dots & \dots & \dots \\ w_{1p} & w_{2p} & \dots & w_{np} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{bmatrix} = \begin{bmatrix} s_1 \\ s_2 \\ \dots \\ s_p \end{bmatrix}, \quad (2.1)$$

где n – число входных переменных;

p – число нейронов в скрытом слое.

Отличие состоит в том, что функция активации этих нейронов является нелинейной. Наиболее часто используется униполярная функция:

$$f(s_i) = \frac{1}{1 + \exp(-b \cdot s_i)} ;$$

или биполярная функция (гиперболический тангенс):

$$f(s_i) = \tanh(-b \cdot s_i) = \frac{1 - \exp(-bs_i)}{1 + \exp(-bs_i)}$$

В этих выражениях коэффициент b определяет "крутизну" функций и выбирается разработчиком сети.

Таким образом, за счет функции активации, сигналы с входных нейронов нелинейным способом преобразуются в выходные сигналы нейронов скрытого слоя:

$$\begin{bmatrix} s_1 \\ s_2 \\ \dots \\ s_p \end{bmatrix} \xrightarrow{f^a} \begin{bmatrix} h_1 \\ h_2 \\ \dots \\ h_p \end{bmatrix}$$

т.е. $h_n = f^a(s_n)$.

Выходной сигнал формируется путем взвешенного суммирования сигналов с нейронов скрытого слоя:

$$[v_1 \quad v_2 \quad \dots \quad v_p] \cdot \begin{bmatrix} h_1 \\ h_2 \\ \dots \\ h_p \end{bmatrix} = s_B$$

В общем случае, выходной сигнал также может формироваться с помощью нелинейной функции активации: $y = f^b(s_B)$.

Применение трехслойной структуры и нелинейных функций активации значительно повышает эффективность аппроксимирующих возможностей рассматриваемой сети по сравнению с адаптивным фильтром и линейной нейронной сетью, представленной на Рис.1.4. Такая сеть с вектором входных

переменных, размерностью n и с одним выходным сигналом y с учетом переменной $x_0 = 1$, вводимой для инициализации сети, описывается в общем виде уравнением:

$$y(\mathbf{x}) = f(x_1, x_2, \dots, x_n) = f^b \left(\sum_{j=1}^p v_j f^a \left(\sum_{i=0}^n w_{ij} x_i \right) + v_{01} x_0 \right). \quad (2.2)$$

Т.е. функция от многих переменных $x = (x_1, x_2, \dots, x_n)$ определяется через композицию простых функций.

Для проведения анализа аппроксимирующих свойств отдельных нейронных сетей и особенно ансамблей целесообразно использование выражений вида (2.2) в более компактной векторной форме:

$$y(\mathbf{x}) = f^b \left(\mathbf{v}_r^T \mathbf{f}_r^a(w\mathbf{x}) \right), \quad (2.3)$$

где $\mathbf{v}_r^T = [\mathbf{v}^T : v_0]$; $\mathbf{f}_r^a(w\mathbf{x}) = [[\mathbf{f}^a(w\mathbf{x})]^{\leftrightarrow T} : x_0]^T$ – составные матрица-строка и матрица-столбец.

Для случаев, когда нейронная сеть имеет m выходов, т.е. $\mathbf{y}(\mathbf{x})$ представляет матрицу-столбец, размерностью $m \times 1$, выражение (2.2) для k -того ($k = 1, 2, \dots, m$) выхода будет иметь следующий вид:

$$y_k(\mathbf{x}) = f^b \left(\sum_{j=1}^p v_{kj} f^a \left(\sum_{i=0}^n w_{ij} x_i \right) + v_{01} x_0 \right). \quad (2.4)$$

Или в матричной форме

$$\mathbf{y}(\mathbf{x}) = f^b \left(\mathbf{v}_r^T \mathbf{f}_r^a(w\mathbf{x}) \right), \quad (2.5)$$

где: $\mathbf{v}_r^T = [\mathbf{v}^T : \mathbf{v}_0^T]$;

$\mathbf{f}_r^a(w_1\mathbf{x}) = [[\mathbf{f}^a(w\mathbf{x})]^{\leftrightarrow T} : [\mathbf{x}_0]^T]^T$;

$\mathbf{v}_0^T = [v_{01}, v_{02}, \dots, v_{0m}]$;

\mathbf{x}_0 – единичная матрица столбец ($m \times 1$).

Из выражений (2.2) и (2.4) следует, что принцип работы нейронной сети с одним скрытым слоем согласуется с теоремой А.Н. Колмогорова, в соответствии с которой функцию многих переменных можно представить в виде сложения и суперпозиции непрерывных функций одной переменной [40].

$$f(\mathbf{x}) = f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{2n+1} f_q \left(\sum_{p=1}^n f_p^q(x_p) \right), \quad (2.6)$$

где f_q и f_p^q – функции одной переменной.

Функции f_q и f_p^q должны быть непрерывными и не дифференцируемые (так называемые особые функции). Потому теорема Колмогорова имеет чисто теоретическое значение. На практике задача представления функции многих переменных в виде сложения и суперпозиции непрерывных функций одной переменной заменяется задачей аппроксимации с допустимой погрешностью в виде функционального ряда. Оценим преимущества функциональной аппроксимации по сравнению с линейной регрессионной аппроксимацией.

На основе теоремы Стоуна-Вейерштрасса, как доказано в [41-43], существует линейный ряд из p слагаемых, который удовлетворяет следующему неравенству:

$$\max_{\mathbf{x}} = f(\mathbf{x}) - \left| \sum_{i=0}^p a_i (f_o)^i(x + b_o) \right| < \varepsilon, \quad (2.7)$$

где a_i, b_o – коэффициенты смещения,
 ε – ошибка аппроксимации.

Т.е. любую функцию многих переменных можно аппроксимировать со сколь угодно малой погрешностью с помощью линейной комбинации функционального ряда смещенных и монотонно ограниченных функций. В качестве каких функций могут быть использованы, рассмотренные выше, сигмоидальные функции.

В случае, когда функции активации скрытого и выходного слоев приняты линейными, в частности, с коэффициентом наклона равным единице, выражение (2.2) примет следующий вид:

$$\hat{y}(\mathbf{x}) = f(x_1, x_2, \dots, x_n) = \sum_{j=1}^p v_j \sum_{i=0}^n w_{ij} x_i + v_{01} x_0. \quad (2.8)$$

Приведя подобные члены получим:

$$\hat{y}(\mathbf{x}) = \sum_{i=0}^n w_{ir} x_i = w_{1r} x_1 + w_{2r} x_2 + \dots + w_{nr} x_n, \quad (2.9)$$

где
$$w_{ir} = [v_1 v_2 \dots v_p] \begin{bmatrix} w_{i1} \\ w_{i2} \\ \vdots \\ w_{ip} \end{bmatrix} = \mathbf{v} \mathbf{w}_i$$

Следовательно, получаем линейный регрессионный ряд, т.е. многослойная нейронная сеть приводится к однослойной.

Таким образом, принципиально важно, чтобы, как минимум, промежуточный слой имел нелинейные функции активации. Это придает нейронной сети как «аппроксиматору» принципиально новое свойство – функциональную аппроксимацию, которую можно представить как замену коэффициентов в регрессии на функции от аргументов регрессионного ряда.

С учетом функций промежуточного слоя в соответствии со схемой нейронной сети на Рис.2.1 и системой уравнений (2.1) при линейной функции активации в третьем слое выходной сигнал будет определяться выражением:

$$\hat{y}(\mathbf{x}) = [f^a(\mathbf{w}_1 \mathbf{x}) \quad f^a(\mathbf{w}_2 \mathbf{x}) \quad \dots \quad f^a(\mathbf{w}_p \mathbf{x})] \begin{bmatrix} v_1 \\ v_2 \\ \dots \\ v_p \end{bmatrix}. \quad (2.10)$$

или в форме функционального ряда:

$$\hat{y}(\mathbf{x}) = \sum_{j=1}^p v_j f^a(\mathbf{w}_j \mathbf{x}) = v_1 f^a(\mathbf{w}_1 \mathbf{x}) + v_2 f^a(\mathbf{w}_2 \mathbf{x}) + \dots + v_p f^a(\mathbf{w}_p \mathbf{x}). \quad (2.11)$$

Выражения (2.10) и (2.11) аппроксимируют $y(\mathbf{x}) = f(x_1, x_2, \dots, x_n)$ с некоторой погрешностью $E\{e(\mathbf{x})\} = E\{y(\mathbf{x}) - \hat{y}(\mathbf{x})\}$.

Для оценки погрешности аппроксимации, на основе которой осуществляется прогнозирование, используются следующие общепринятые показатели:

- среднее отклонение (СО):

$$\varepsilon_{\text{со}} = \frac{1}{n} \sum_{n=1}^n \frac{|P_{\text{пр}} - P_{\phi}|}{P_{\phi}} \quad 100\%; \quad (2.12)$$

- среднеквадратичное отклонение (СКО):

$$\varepsilon_{\text{ско}} = \frac{1}{n} \sum_{n=1}^n \frac{(P_{\text{пр}} - P_{\phi})^2}{P_{\phi}^2} \quad 100\%. \quad (2.13)$$

В (2.12) и (2.13) обозначено: $P_{\text{пр}}$ – прогнозное значение потребления электроэнергии; P_{ϕ} – фактическое значение потребления электроэнергии; n – число отдельных прогнозов.

Однако в связи со спецификой требований к системам управления в электроэнергетической отрасли требуется оценка каждого значения (отсчета) прогноза. Поэтому необходимо учитывать величину разброса или дисперсию значений погрешностей прогноза. Для этого будем использовать (по аналогии с плотностью вероятности) такой показатель, как представление распределения погрешности прогнозирования в определенных интервалах значения этой погрешности:

$$\varepsilon_i = \frac{|P_{\text{пр}} - P_{\phi}|}{P_{\phi}} 100\% \leq \Delta_i. \quad (2.14)$$

Тогда, численно плотность распределения погрешностей прогнозирования будет определяться как количество прогнозов n_i , погрешность которых находится в интервале, определяемом выражением (2.14) или процент получаемых прогнозов с погрешностями, находящимися в этом интервале:

$$\eta_i = \frac{n_i}{N} 100\%, \quad (2.15)$$

где N – общее число прогнозов (например, при почасовом прогнозе на сутки вперед $N = 24$).

Исходя из требований к качеству прогнозирования, используются следующие интервалы оценки ошибок: $\Delta_i = 0-3\%$ – отличное качество прогноза; $\Delta_i > 3-5\%$ – хорошее качество прогноза; $\Delta_i > 5-10\%$ – удовлетворительное качество прогноза; $\Delta_i > 10\%$ – неудовлетворительное качество прогноза.

Необходимость учета дисперсии или показателя (2.14) определяется тем, что в практическом плане показатели СО и СКО, которые обычно используют, отражают усредненную погрешность прогнозирования. Например, при получении двух соседних почасовых прогнозов с ошибками, равными 4% и 0%, средняя ошибка будет равна 2%. Та же оценка погрешности прогнозирования получается и в том случае, если оба почасовых прогноза имеют одинаковые погрешности,

равные 2%. Очевидно, что второй прогноз предпочтительней, хотя оба прогноза имеют одинаковую среднюю погрешность.

В связи с этим возникает вопрос о максимально необходимой точности прогнозирования, при которой дальнейшее уменьшение погрешности не целесообразно. Если принять, что все погрешности почасовых прогнозов с равной вероятностью попадают в первый интервал ($\Delta_i = 0-3\%$), то усредненная погрешность будет равна 1,5%. Уменьшение погрешности менее 1,5%, как правило, сопряжено со значительными усложнениями процесса прогнозирования. При этом достигнутая точность прогнозирования для одного периода не гарантируется для других. Соответственно, следующий интервал оценок погрешностей определяет, что если усредненная погрешность меньше 2,5%, то качество прогнозирования можно оценить, как хорошее. Дальнейшее расширение интервала допустимых погрешностей до 10% определяет удовлетворительную оценку прогнозирования, если средняя погрешность меньше 5%.

При разных наборах входного множества аргументов $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m$ и значениях выходного $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m$ сигнала, по которым осуществляется обучение нейронной сети, аппроксимируемые значения можно представить в виде следующей системы уравнений:

$$\begin{bmatrix} \hat{y}(\mathbf{x}_1) \\ \hat{y}(\mathbf{x}_2) \\ \dots \\ \hat{y}(\mathbf{x}_p) \end{bmatrix} = \begin{bmatrix} f^a(\mathbf{w}_1\mathbf{x}) & f^a(\mathbf{w}_1\mathbf{x}) & \dots & f^a(\mathbf{w}_1\mathbf{x}) \\ f^a(\mathbf{w}_2\mathbf{x}) & f^a(\mathbf{w}_2\mathbf{x}) & \dots & f^a(\mathbf{w}_2\mathbf{x}) \\ \dots & \dots & \dots & \dots \\ f^a(\mathbf{w}_p\mathbf{x}) & f^a(\mathbf{w}_p\mathbf{x}) & \dots & f^a(\mathbf{w}_p\mathbf{x}) \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ \dots \\ v_p \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_k \end{bmatrix}. \quad (2.16)$$

Определение оптимальных значений весовых коэффициентов по минимуму среднеквадратичной ошибки по аналогии с (1.9) определяется выражением:

$$\mathbf{v} = [\mathbf{F}^T \mathbf{F}]^{-1} \mathbf{F}^T \mathbf{y} \quad (2.17)$$

Но решение этого уравнения также, как и в случае авторегрессионной аппроксимации, связано с необходимостью определения автокорреляционной матрицы \mathbf{F} функций активации скрытого слоя. Поэтому на практике оптимальные коэффициенты веса (или синаптические коэффициенты) определяются итерационным способом при обучении сети, как правило, градиентными методами.

В результате оценки аппроксимирующих свойств нейронных сетей можно сделать вывод, что эффективные сети, т.е. имеющие минимальную погрешность прогнозирования, должны быть, как минимум, трехслойными и скрытый слой должен иметь нелинейные сигмоидальные функции активации.

2.2. Определение состава входных векторов

После определения основных характеристик структуры эффективных нейронных сетей, следующей по важности, является задача определения состава входного вектора или набора факторов, по которым осуществляется прогнозирование электропотребления.

Анализ большого числа имеющихся на эту тему публикаций показывает, что способы формирования входного вектора для обучения нейронных сетей и использования его в дальнейшем для прогнозирования электропотребления отличаются большим разнообразием, а разработанные рекомендации имеют эмпирический и декларативный характер. Например, размеры используемых входных векторов находятся в диапазоне от 4 параметров [31] до 148 [44, 45] и даже 336 [46]. Основными параметрами, которые принимаются во внимание, являются: [47-56]:

- ретроспективные данные электропотребления с разной глубиной охвата;
- метеофакторы (температура воздуха, скорость ветра, влажность, давление, облачность);
- сезонные факторы (сезонность изменений энергопотребления, продолжительность светового дня);
- особенности графиков нагрузки (день недели, тип дня – рабочий, выходной, предпраздничный, праздничный и т.д.).

Для уменьшения размерности входного вектора в некоторых работах используется метод главных компонент [57,58]. Особую группу составляют прогнозные модели производственных предприятий и электрического транспорта. Существенными факторами для них являются графики работы оборудования, смена вида выпускаемой продукции, расписание движения электропоездов и т.п.

[59,60,61]. В ряде работ особое внимание уделяется составлению прогнозов для, так называемых «нерегулярных дней» [62], под которыми понимаются праздничные и предпраздничные дни.

В связи с этим требуется проведение отдельного исследования по определению наиболее информационного и технологичного для разработки нейронных моделей состава входных векторов для различных видов прогнозирования.

При формировании входного вектора для обучения нейронных сетей и последующего прогнозирования используется два основополагающих принципа:

- входной вектор должен иметь минимальную размерность, что должно обеспечить минимизацию структуры нейросетевых моделей;
- состав входного вектора и ретроспективная выборка при обучении нейросетей определяются на основе максимального подобия для обеспечения максимальной точности прогнозирования при ограниченном объеме обучающей выборки.

Таким образом, при определении набора значимых параметров имеет место противоречие между необходимостью учесть все факторы, имеющие влияние на значение потребления электроэнергии, а с другой стороны, сформировать, по возможности, входной вектор минимальной размерности, чтобы излишне не усложнять нейронную сеть и процедуру её обучения. Учет избыточного количества факторов, влияющих на потребление электроэнергии, не гарантирует повышение точности прогнозирования, так как компоненты входного вектора могут иметь высокую степень корреляции и дополнительные существенные погрешности.

Для решения этого противоречия представим множество возможных значимых факторов в виде системы трех подмножеств:

$$V = \langle C \ X \ U \rangle, \quad (2.18)$$

где C – подмножество, пользуясь терминологией, предложенной в [26], статических переменных, которые несут информацию о моменте времени, для которого осуществляется прогнозирование;

X – динамические переменные или факторы, представляющие ретроспективные данные потребления;

U – уточняющие факторы: длительность светового дня, средняя температура и другие погодные условия, графики работы наиболее значимых потребителей и т.д.

Для краткосрочного прогнозирования подмножество статических переменных C содержит следующие элементы:

$$C = \{T D M\}, \quad (2.19)$$

где $T = \{1, 2, 3, 4, \dots, 24\}$ – значение часа, для которого осуществляется прогнозирование (идентификация часа);

$D = \{1, 2, 3, 4, 5, 6, 7\}$ – номер дня недели (идентификация дня:

1 – понедельник, 2 – вторник, ..., 7 – воскресенье);

$M = \{1, 2, 3, 4, 5, 6, 7, \dots, 12\}$ – номер месяца (идентификация месяца: 1 – январь, 2 – февраль, ..., 12 – декабрь).

Для определения подмножества динамических переменных целесообразно использовать принцип максимального подобия. В работе [67] на основе коэффициента корреляции вводится мера подобия выборок. На основе этой меры, из имеющихся ретроспективных данных выбирается максимально подобная выборка той выборке, которая непосредственно предшествует прогнозируемому периоду.

В качестве показателя степени подобия временных рядов можно применить индекс Тейла, который основывается на методе наименьших квадратов:

$$I(X, Y) = \sqrt{\frac{\sum_{i=1}^N (X_i - Y_i)^2}{\sum_{i=1}^N X_i^2 + \sum_{i=1}^N Y_i^2}}$$

где X_i и Y_i – значения сравниваемых временных рядов в i -тые моменты времени.

Очевидно, что нейронная сеть, обученная на максимально подобной выборке, должна дать наиболее точный прогноз. Однако применение непосредственно данного метода сопряжено с большим количеством вычислительных операций по определению методом перебора размера и местоположения во временном ряде подобных выборок. Дополнительно при использовании нейронных сетей необходима не только максимально подобная

выборка, но она должна быть достаточно представительной, чтобы обеспечить эффективность обучения нейросети.

Другой подход выявления максимального подобия основывается на применении нейронных сетей-классификаторов, типа карты Кохонена [65]. Однако это также приводит к усложнению технологии прогнозирования и проблеме достаточности объема ретроспективных данных, сгруппированных в тот или иной кластер подобия. Поэтому при определении размера и местоположения во временном ряде подобных выборок подмножества динамических переменных на основе принципа максимального подобия используем очевидную гипотезу, что ретроспективные выборки данных, которые априори должны иметь максимально подобные графики нагрузки электропотребления относятся к одинаковым дням недели, сезона и типа дня.

Для определения размера подмножества ретроспективных динамических переменных X применим авторегрессионную аппроксимацию. Аналогично (1.1) представим выражение для прогнозируемого значения потребления электроэнергии в определенный k -тый час времени в виде авторегрессии электропотребления в предыдущие i -тые дни в тот же самый час:

$$\hat{x}_k(n+1) = \sum_0^i w_i x_k(n-i) + \varepsilon_k, i \in 1, 2, \dots, 7.$$

Необходимо рассмотреть ретроспективу в 7 дней исходя из того, что величины потребления в эти дни наиболее близки прогнозируемому потреблению. Коэффициенты регрессии рассчитываются из условия минимума среднеквадратичной ошибки, используя выражение (1.8). Результаты расчета представлены в Табл. 2.1.[64].

Табл. 2.1. Результаты расчета коэффициентов регрессии.

i	0	1	2	3	4	5	6	7
ε_k	4,426	4,338	4,276	3,980	3,948	3,921	3,917	3,915

Как следует из таблицы, увеличение ретроспективных данных более чем на 5 суток не дает ощутимого уменьшения погрешности прогнозирования.

В результате получается довольно компактный входной вектор:

$$I_{mp} = \{X_{N-1}; X_{N-2}; X_{N-3}; X_{N-4}; X_{N-5}; T; D; M \}. \quad (2.20)$$

Дальнейшим усовершенствованием входного вектора является определение из имеющегося набора наиболее значимого фактора. Очевидно, что таким фактором является идентификация часа T . Как правило, усиление действия какого-либо фактора осуществляется увеличением количества синаптических связей соответствующего нейрона входного слоя с нейронами скрытого слоя. Однако это приводит к асимметрии скрытого слоя нейронной сети. Поэтому более целесообразно продублировать фактор T в соответствии с количеством ретроспективных данных о почасовом потреблении электроэнергии. Таким способом размерность входного вектора увеличивается до 12:

$$I_{mp} = \{X_{N-1}; X_{N-2}; X_{N-3}; X_{N-4}; X_{N-5}; T; T; T; T; T; D; M \}. \quad (2.21)$$

Функциональная схема обучения нейронной сети с таким входным вектором представлена на Рис.2.2.

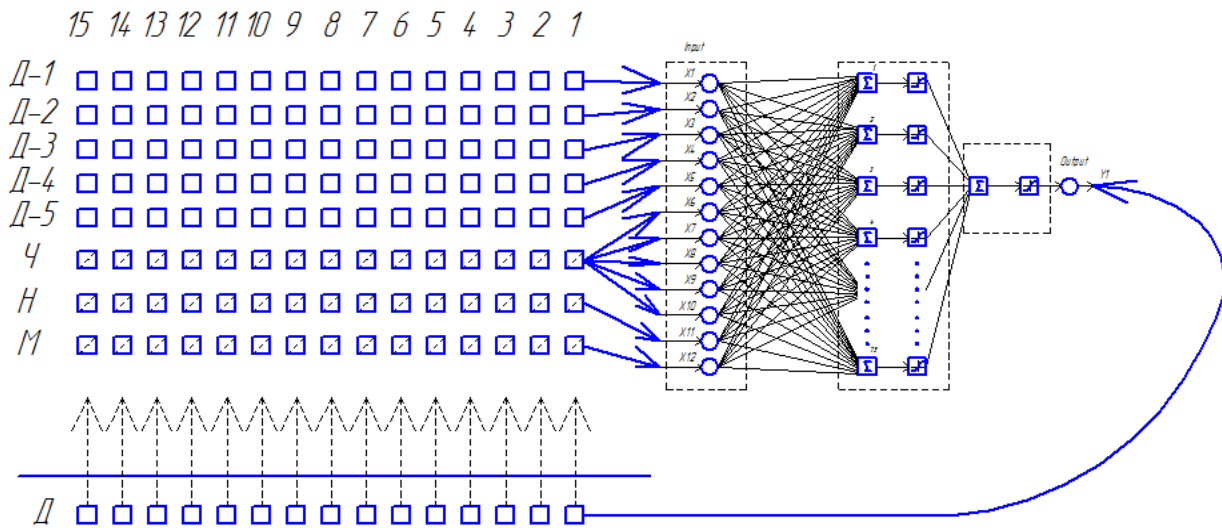


Рис.2.2. Функциональная схема обучения нейронной сети по входному вектору, имеющему размерность, равную двенадцати

Данное решение подтверждается экспериментально. В Табл. 2.2 приведены сравнительные данные результатов прогнозирования для октября месяца с использованием 8 и 12 размерного входного вектора для нейросети с прямым распределением и задержкой по времени.

Табл. 2.2. Результаты прогнозирования при 8 и 12 размерных входных векторах

Размерность входного вектора	Плотность распределения погрешностей прогнозирования (количество и проценты)			
	0-3%	3-5%	5-10%	>10%
8	74 44%	49 29,2%	40 23,8%	5 3%
12	87 51,8%	47 28%	34 20,2%	0 0 %

Следующей проблемой является определение состава уточняющих факторов U . В большинстве существующих работ в основном принимаются во внимание погодные или метеорологические условия и, в первую очередь, температура. Исследования показывают, что при краткосрочном прогнозировании график изменения температуры с графиком потребления электроэнергии имеет коэффициент корреляции Пирсона:

$$r_{xq} = \frac{cov(x_k q_k)}{\sigma_x \sigma_q} \geq 0,6,$$

где x_k, q_k – соответственно, значения электропотребления и температура в k -тый момент (час) времени ($k \in 0,1, \dots, 24$);

σ_x, σ_q – дисперсии графиков электропотребления и температуры;

$$cov(x_k q_k) = \frac{\sum_{k=1}^{24} (x_k q_k)}{24} - \frac{\sum_{k=1}^{24} x_k \sum_{k=1}^{24} q_k}{24}.$$

Таким образом, температурный график уже отражается подобно в графике электропотребления. Кроме того, максимальное значение коэффициента корреляции отстает от графика электропотребления на 2-6 часов, что связано с тем, что реакция изменения электропотребления на увеличение или уменьшение температуры происходит с запаздыванием. Время запаздывания не постоянно и зависит от интенсивности изменения температуры, знака этих изменений, времени суток и ряда других факторов. Поэтому, учет прогноза температуры не приводит к уменьшению погрешности краткосрочного прогноза электропотребления, а чаще всего даже увеличивает эту погрешность. Этот вывод совпадает с результатами, приведенными в [26].

Наиболее значимым из уточняющих факторов для рассматриваемого типа потребителей, приставляющих, в основном, мелко моторные потребление и ЖКХ, является тип дня: рабочий, выходной или праздничный и предпраздничный. Соответственно, входной вектор нейронной сети должен содержать дополнительный идентификатор, определяющий тип дня:

$$U = \langle r \ v \ p \rangle,$$

где $r = 0$ – рабочие дни;

$v = 1$ – выходные и праздничные дни;

$p = 2$ – предпраздничные дни.

В этом случае размерность входного вектора увеличивается до 13:

$$I_{mp} = \{X_{N-1}; X_{N-2}; X_{N-3}; X_{N-4}; X_{N-5}; T; T; T; T; T; D; M; U\}. \quad (2.22)$$

Применение вектора (2.22) особенно необходимо при составлении прогнозов в такие «неудобные» месяцы, как январь и май. Во всех работах просматривается ухудшение в эти месяцы точности прогнозирования, т.к. именно они имеют большое количество дополнительных выходных дней.

Экспериментальные результаты прогнозов для января, представленные в Табл. 2.3, подтверждают целесообразность введения идентификатора типа дня.

Табл. 2.3. Сравнительные результаты экспериментов по влиянию фактора U

Название нейронной сети	Размерность входного вектора	Плотность распределения погрешностей (количество и проценты)			
		0-3%	3-5%	5-10%	>10%
Нейросеть с прямым распределением	12	549 76.3%	127 17.6%	36 5%	8 1.1%
Нейросеть с прямым распределением	13	571 79.3%	119 16.5%	30 4.2%	0 0 %

Более сложной задачей является определение входного вектора для среднесрочного прогнозирования от недели до месяца. В связи с этим работ, посвященных среднесрочному и долгосрочному прогнозированию в разы меньше [20, 30, 41], чем работ по краткосрочному прогнозированию.

Прогнозирование на неделю вперед целесообразно осуществлять путем прогнозирования отдельно по дням недели и затем суммирования потребления за семь суток. Входной вектор должен содержать данные суточного потребления электроэнергии с ретроспективой в пять недель, чтобы иметь возможность учитывать сезонные изменения и общий тренд текущего месяца:

$$\{X_{N-35}; X_{N-28}; X_{N-21}; X_{N-14}; X_{N-7};\}$$

где N – первые сутки прогноза.

Подмножество статических переменных, очевидно, должно содержать следующие элементы:

$$C = \{D M\},$$

$D = \{1, 2, 3, 4, 5, 6, 7\}$ – номер дня недели (идентификация дня:

1 – понедельник, 2 – вторник, ..., 7 – воскресенье);

$M = \{1, 2, 3, 4, 5, 6, 7, \dots, 12\}$ – номер месяца (идентификация месяца: 1 – январь, 2 – февраль, ..., 12 – декабрь).

Состав входного вектора размерностью 7 будет иметь следующий вид:

$$I_{mp} = \{X_{N-35}; X_{N-28}; X_{N-21}; X_{N-14}; X_{N-7}; D; M\} \quad (2.23)$$

Для обеспечения максимального подобия ретроспективных графиков нагрузки обучение начинается с недельным отступлением.

Прогнозирование на месяц вперед целесообразно осуществлять также путем получения прогнозов отдельно по дням недели и затем суммирования потребления за 28, 30 или 31 сутки.

Входной вектор включает в себя динамические переменные:

$\{X_{N-31}\}$ – данные суточного потребления электроэнергии (со сдвигом на 31 сутки или на 28, или на 30), где N – первые сутки прогноза.

Поскольку прогнозирование электропотребления сразу на тридцать одни сутки вперед является более сложной задачей, в подмножество статических переменных вводится дополнительный фактор – календарное число прогнозируемого дня месяца.

Таким образом подмножество статических переменных будет содержать следующие элементы:

$D = \{1, 2, 3, 4, 5, 6, 7\}$ – номер дня недели (идентификация дня: 1 – понедельник, 2 – вторник, ..., 7 – воскресенье);

$Z = \{1, 2, 3, 4, \dots, 31\}$ – календарное число (идентификация календарного числа);

$M = \{1, 2, 3, 4, 5, 6, 7, \dots, 12\}$ – номер месяца (идентификация месяца: 1 – январь, 2 – февраль, ..., 12 – декабрь).

Состав входного вектора получается размерностью, равной четырем, и определяется выражением:

$$I_{mp} = \{X_{N-31}; D; Z; M; \}. \quad (2.24)$$

Целевой вектор: $\{X_N\}$ – данные суточного потребления энергии.

Объем обучающей выборки формируется из данных посуточного потребления за 5 лет.

Установлено, что *долгосрочное прогнозирование на год вперед* может осуществляться с помощью суммирования помесечных прогнозов на основе рассмотренного выше входного вектора или также путем суммирования прогнозного посуточного потребления за 365 суток. Во втором методе по аналогии с помесечным прогнозированием входной вектор формируется из следующих переменных:

$\{X_{N-365}\}$ – данные суточного потребления (со сдвигом на 365 суток);

$D = \{1, 2, 3, 4, 5, 6, 7\}$ – номер дня недели (идентификация дня: 1 – понедельник, 2 – вторник, ..., 7 – воскресенье);

$Z = \{1, 2, 3, 4, \dots, 31\}$ – календарное число (идентификация календарного числа);

$M = \{1, 2, 3, 4, 5, 6, 7, \dots, 12\}$ – номер месяца (идентификация месяца: 1 – январь, 2 – февраль, ..., 12 – декабрь).

Таким образом, состав входного вектора будет определяться выражением:

$$I_{mp} = \{X_{N-365}; D; Z; M; \}. \quad (2.25)$$

Целевой вектор, используемый для обучения ИНС (Target):

$\{X_N\}$ – данные суточного потребления энергии.

2.3. Обоснование структуры эффективных нейронных сетей

Как было установлено ранее, формирование универсального ансамбля для прогнозирования потребления электроэнергии должно осуществляются на основе

системы эффективных нейронных сетей. Под эффективными, как уже определялось, понимаются такие нейронные сети, которые обеспечивают прогнозирование с минимально возможной погрешностью. Исходными данными для формирования таких сетей для краткосрочного прогнозирования являются:

- размерность входного вектора – 13;
- размерность выходного вектора (сигнала) прогноза потребления для конкретного времени (часа) суток – 1;
- объем обучающей выборки – ретроспективные данные почасового потребления электроэнергии за два предыдущих года ≈ 17520 .

В разделе 2.1 было доказано, что наиболее эффективными являются трехслойные нейронные сети. Следовательно, при заданных размерах входного слоя – 13 нейронов и выходного – 1 нейрон требуется определить необходимое количество нейронов в промежуточном слое. Для этого используем результаты исследования, представленные в [66]. В данной работе доказано, что для бинарной классификации в многослойной сети с сигмоидальными передаточными функциями число настраиваемых синаптических весов N_V должно быть

$$\frac{N_x N_o}{1 + \log_2(N_o)} \leq N_V, \quad (2.26)$$

где N_x – размерность входного вектора;

N_o – объем или число элементов обучающей выборки.

Подставив в (2.26) исходные данные, получим:

$$\frac{1 \cdot 17520}{1 + \log_2 17520} = \frac{17520}{1 + 14,1} = 1160.$$

Следовательно, число нейронов в скрытом слое должно быть примерно 75, так как число синаптических весов равно $13 + 13 \cdot 75 + 75 + 1 = 1139$.

Другой подход базируется на использовании меры Вапника-Червоненкиса, обозначаемой, как $VCdim$ и определяемой следующим образом [67,68]:

$$LN_x \leq VCdim \leq 2N_V(1 + \lg M), \quad (2.27)$$

где L – число нейронов в скрытом слое;

M – общее число нейронов.

Из (2.27) следует, что минимальное число $VCdim$ примерно равно числу синаптических связей входного и скрытого слоя, а верхняя граница этой меры должна двукратно превышать общее число синаптических связей сети.

При использовании нейронной сети с одним скрытым слоем, имеющим 75 нейронов, для прогнозирования почасового потребления на сутки вперед количество обучающих выборок в проводимых исследованиях должно браться в пределах, определяемых выражением:

$$13 \cdot 75 \leq N_V \leq 2(13 \cdot 75 + 75) \cdot (1 + \lg(13 + 75 + 1)),$$

или

$$975 \leq N_V \leq 6300.$$

Для того чтобы сеть обладала свойствами обобщения, необходимо соблюдение зависимости:

$$\frac{N_V}{VCdim} \geq k,$$

где N_V – общее число обучающих выборок;

k – коэффициент превышения числа обучающих выборок над мерой Вапника-Червоненкиса.

Чем больше число k , тем больше доверительный интервал получения точности прогнозирования, получаемой в процессе обучения, и тем выше обобщающие свойства нейронной сети [66,69]. Экспериментальные исследования показывают, что погрешность прогнозирования не превышает погрешности, получаемой при обучении при коэффициенте $k = 2 \div 3$. Сеть в этом случае обладает свойствами обобщения.

При $k = 2$ объем обучающей выборки практически равен числу данных почасового потребления электроэнергии за два года. Таким образом, второй подход подтверждает предыдущий расчет необходимого количества нейронов в скрытом слое.

В Табл. 2.4 приведены экспериментальные результаты погрешностей прогнозирования в зависимости от количества нейронов в скрытом слое при использовании трехслойной нейросети с прямым распределением. С целью

получения сопоставимых результатов прогнозирования электропотребления для различных видов прогнозов в проводимых экспериментах используется один и тот же тип ИНС – нейросеть с прямым распределением и задержкой по времени. Выбор такой ИНС обусловлен тем, что в ней происходит разбиение временного ряда на небольшие отрезки времени, которые подаются на сумматор. Вследствие чего данная ИНС позволяет определять нелинейные зависимости между переменными на основе больших массивов. Поэтому автоматизированные системы прогнозирования электропотребления, построенные на основе искусственной нейронной сети с прямым распределением и задержкой по времени, обладают наибольшей универсальностью.

Табл. 2.4. Результаты погрешностей прогнозирования при использовании нейросети с прямым распределением

Кол-во нейронов	Плотность распределения погрешностей прогнозирования (количество и проценты)				СО СКО (%)
	0-3%	3-5%	5-10%	>10%	
10	496 68.9%	138 19.2%	78 10.8%	8 1.1%	2,36 3,22
20	557 77.3%	125 17.4%	33 4.6%	5 0.7%	2,00 2,66
30	586 81.4%	91 12.6%	40 5.6%	3 0.4%	1,86 2,48
40	538 74.7%	130 18%	45 6.3%	7 1%	2,16 2,87
50	521 72.3%	149 20.7%	43 6%	7 1%	2,22 2,89
60	550 76.4%	139 19.3%	29 4%	2 0.3%	2,03 2,65
70	554 77%	107 14.8%	57 7.9%	2 0.3%	2,15 2,87
75	551 76.8%	117 16.2%	47 6.3%	5 0.7%	2,05 2,74
80	534 74.2%	131 18.2%	52 7.2%	3 0.4%	2,13 2,78

Как видно из этой таблицы нейросеть с прямым распределением имеет два пика точности в интервале от 20 до 35 и в интервале от 60 до 75 нейронов.

В Табл. 2.5 приведены результаты точности прогнозирования в зависимости от количества нейронов в скрытом слое при использовании также нейросети с прямым распределением и задержкой по времени.

Нейросеть имеет также два пика точности при 30 и при 70 нейронах.

На основе данных экспериментов и экспериментов с другими видами нейронных сетей следует вывод, что нейросети имеют несколько пиков точности: при минимальном числе нейронов (нижняя граница) – от 10 до 55; при максимальном числе нейронов (верхняя граница) – от 70 до 75. При этом нижняя граница количества нейронов является размытой и зависит от типа нейросети.

Табл. 2.5. Результаты прогнозирования при использовании нейросети с прямым распределением и задержкой по времени

Кол-во нейронов	Плотность распределения погрешностей прогнозирования (количество и проценты)				СО СКО (%)
	0-3%	3-5%	5-10%	>10%	
10	490	161	63	6	2,39
	68%	22.4%	8.8%	0.8%	3,14
20	546	126	41	7	2,08
	75.7%	17.5%	5.7%	0,9%	2,83
30	583	102	35	0	1,88
	81%	14.2%	4.8%	0 %	2,41
40	570	109	38	3	2,02
	79.3%	15%	5.3%	0.4%	2,60
50	565	117	37	1	1,97
	78.5%	16.3%	5%	0,2%	2,54
60	554	125	37	4	2,13
	77%	17.4%	5%	0,6%	2,74
70	576	106	36	2	1,88
	80%	14.7%	5%	0.3%	2,48
75	561	118	36	5	2,06
	77.9%	16.4%	5%	0.7%	2,85

Вследствие этого, для создания систем прогнозирования, применимых к различным графикам нагрузки, целесообразно использовать нейросети с верхней границей числа нейронов в скрытом слое. Избыточное число нейронов позволяет аппроксимировать различные, даже очень сложные графики потребления электроэнергии, чем обеспечивается применимость синтезированных систем прогнозирования к различным графикам нагрузки.

2.4. Методики обучения нейронных сетей для прогнозирования электропотребления

В результате проведенных исследований определено, что наиболее перспективными для прогнозирования электропотребления являются сети с прямым распределением и рекуррентные сети. Обучение такого типа сетей осуществляется по методике «обучение с учителем». Сущность этой методики заключается в определении среднеквадратичной ошибки прогнозирования

$$E(t) = \frac{1}{2} \sum_{k=1}^t e_y(k)^2, \quad (2.28)$$

где $e(x) = y(x) - \hat{y}(x)$ – ошибка прогнозирования определяется как разность реального значения и спрогнозированного.

Затем осуществляется подстройка (корректировка) коэффициентов синаптических связей путем минимизации функции ошибки (2.28) методом обратного распространения [26, 70].

Корректировка весовых коэффициентов выходного слоя между связями производится следующим образом:

$$v_j(k+1) = v_j(k) + \eta e_y, \quad (2.29)$$

где: k – номер текущей итерации обучения;

η – коэффициент скорости обучения;

Корректировка весовых коэффициентов скрытого слоя между связями происходит по формуле:

$$w_{ij}(k+1) = w_{ij}(k) + \eta e_j h_j, \quad (2.30)$$

где: e_{ij} – величина разности между фактическим h_j и спрогнозированным \hat{h}_j значением выходной величины.

Для каждого нейрона в скрытом слое должна быть вычислена своя ошибка и скорректированы значения весовых коэффициентов, связанные с этим слоем. Процесс подстройки весовых коэффициентов является завершенным, когда все веса скорректированы.

Для такого метода настройки весовых (синаптических) коэффициентов, получившего название метода обратного распространения ошибки, разработано большое количество способов его реализации [26,65,70]:

- алгоритмы локальной оптимизации, основанные на использовании частных производных первого порядка (градиентный алгоритм или алгоритм скорейшего спуска, алгоритм сопряженных градиентов, алгоритм, учитывающий направление антиградиента и т.д.);

- алгоритмы локальной оптимизации, основанные на использовании частных производных первого и второго порядков (метод Ньютона и его модификации, алгоритм оптимизации с разреженными матрицами Гессе, метод Левенберга-Маквардта и др.);

- алгоритмы стохастической оптимизации;

- алгоритмы глобальной оптимизации.

Наличие большого количества методов и алгоритмов обучения нейронных сетей связано с необходимостью решать одновременно ряд противоречивых задач: определение начальных значений синаптических связей (коэффициентов), получение приемлемой скорости достижения минимума ошибок обучения, решение проблемы «застревания» в локальных минимумах и т.д.

В пакетах прикладных программ, таких как STATISTICA Neural Networks [71] и Neural Network Toolbox (пакет расширения MATLAB) [72] уже заложен выбор алгоритма обучения нейросети в зависимости от ее типа. Поэтому основной задачей при обучении нейронных сетей для прогнозирования электропотребления является «недоученность» или «переученность» нейронной сети. Эти проблемы напрямую связаны со способностью нейронных сетей к обобщению.

Для контроля получаемой точности прогнозирования (или контроля величины погрешности прогнозирования) множество обучающих данных электропотребления \mathbf{R} разделяется на два подмножества: \mathbf{V} – обучающее подмножество и \mathbf{T} – тестовое подмножество таким образом, что

$$\mathbf{V} \cup \mathbf{T} = \mathbf{R}; \mathbf{V} \cap \mathbf{T} = \emptyset.$$

Для контроля способности к обобщению нейронных сетей, т.е. к приобретению свойства определять по ретроспективным данным в процессе обучения функциональную зависимость между входными и выходными переменными (см. 2.11), в обучающем подмножестве V выделяется контрольное подмножество Q , следовательно, $Q \in V$.

После предъявления обучающей пары – входной вектор и ожидаемое (эталонное) значение выходной величины, происходит итерационный процесс обучения нейронной сети методом обратного распространения ошибки. Этот процесс называется эпохой. При этом чем дольше продолжается эпоха, т.е. чем больше число итераций, тем меньше становится погрешность обучения (сплошная линия на Рис.2.3).




Рис.2.3. Графики изменения ошибок EV (сплошная линия) и ET (штриховая линия) от количества итераций обучения

Процесс обучения останавливается, например, как показано на рисунке, через $N_{\max}=500$ итераций при достижении заданной минимальной погрешности обучения E_V .

Однако слишком большое количество итераций приводит к переобучению сети. Аппроксимирующие функции становятся точно настроенными на обучающую пару, т.е. эти функции сужают свою область «действия» в многомерном пространстве входных параметров, и при подаче на вход другого входного вектора, не входящего в обучающее подмножество V , прогнозирование будет происходить с большой погрешностью. Это определяется на тестовом

множестве T . На Рис.2.3. показана типичная зависимость погрешности прогнозирования E_T , определяемая на множестве T , от количества итераций обучения (кривая 2). Поэтому, когда E_T достигает минимального значения (например, $N_{opt} = 240$), процесс обучения прекращается (так называемый «ранний останов»), благодаря чему предотвращается «переобучение» нейронной сети. Поэтому количество циклов обучения наиболее целесообразно определять методом раннего останова с помощью тестирующего множества T .

2.5. Анализ и синтез базисных типов нейронных сетей

Широкий круг задач, решаемых ИНС, не позволяет создавать универсальные ИНС, способные одинаково хорошо решать задачи классификации, аппроксимации и регрессии. Поэтому требуется применение эвристических методов поиска эффективных типов или видов нейронных сетей для каждой решаемой задачи прогнозирования электропотребления.

Как уже отмечалось, в большинстве исследований применяются нейронные сети с прямым распространением (см. Рис.2.1). Однако представляет интерес исследование целесообразности применения других типов нейронных сетей для рассматриваемых видов прогнозов. Проведенные испытания различных типов нейронных сетей показывают, что наряду с нейронной сетью с прямым распространением наиболее эффективными являются:

- нейронная сеть с задержкой по времени;
- нейронная сеть каскадных корреляций (распределения);
- рекуррентные нейронные сети и, в частности, нейронная сеть Элмана.

Нейронные сети с задержкой по времени относятся к классу нейронных сетей динамического типа [26,65]. В нейросети такого типа происходит разбиение временного ряда на небольшие отрезки времени (Рис.2.4). Такое разбиение на интервалы происходит в каждом скрытом слое нейронной сети. В результате входные параметры приходят на сумматор, разбитые на однотипные такты времени. Связь между входом и выходом в общем виде определяется зависимостью:

$$y(\tau) = f \left(\sum_{i=1, j=1}^n x_i(\tau - n) w_j \right), \quad (2.31)$$

где τ – время такта (задержки).

Преимуществом такой нейросети является нахождение более глубоких закономерностей между переменными и получение прогнозирования на основе больших массивов с нелинейной зависимостью.

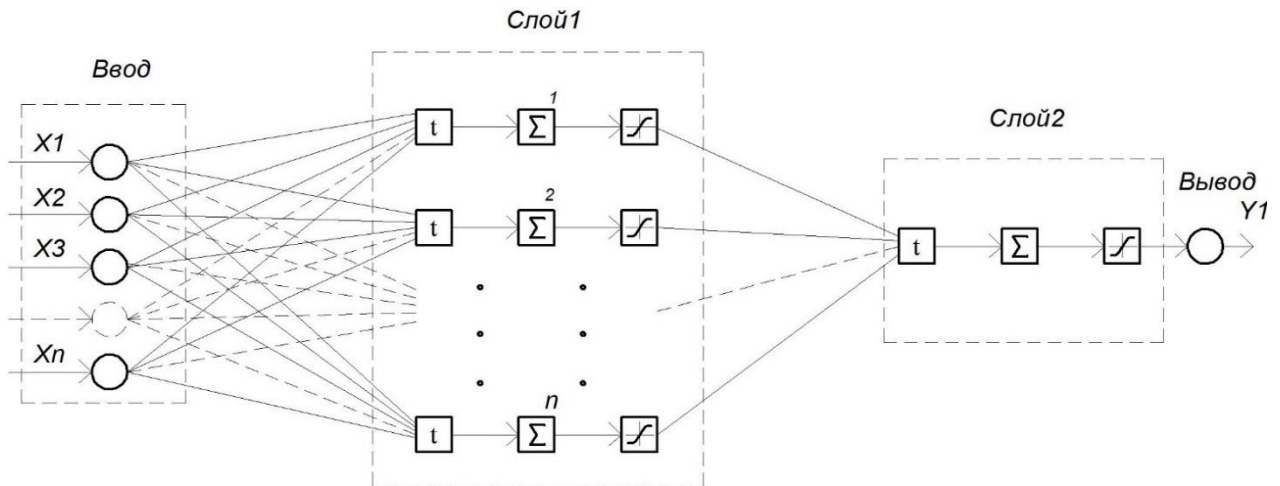


Рис.2.4. Схема нейронной сети с задержкой по времени

Сеть каскадной корреляции (распределения) представляет собой многослойную нейросеть, которая обучается конструктивным способом [26]. В результате по мере обучения к сети добавляются новые нейроны. Алгоритм обучения построен таким образом, что обучается только один слой обучаемых связей. Благодаря этому упрощается обучение сети методом обратного распространения ошибки. Особенность сети состоит в том, что архитектура, размер сети и параметры скорости обучения определяются самим процессом обучения.

Обучение начинается с начальной архитектуры, которая представляет сеть с одним слоем обучаемых связей (Рис.2.5). После обучения сети начального приближения циклически выполняются следующие шаги:

- добавляется нейрон-кандидат и производится обучение его входных связей;
- соединение нейрона-кандидата с входами выходного слоя сети и обучение связей этого слоя.

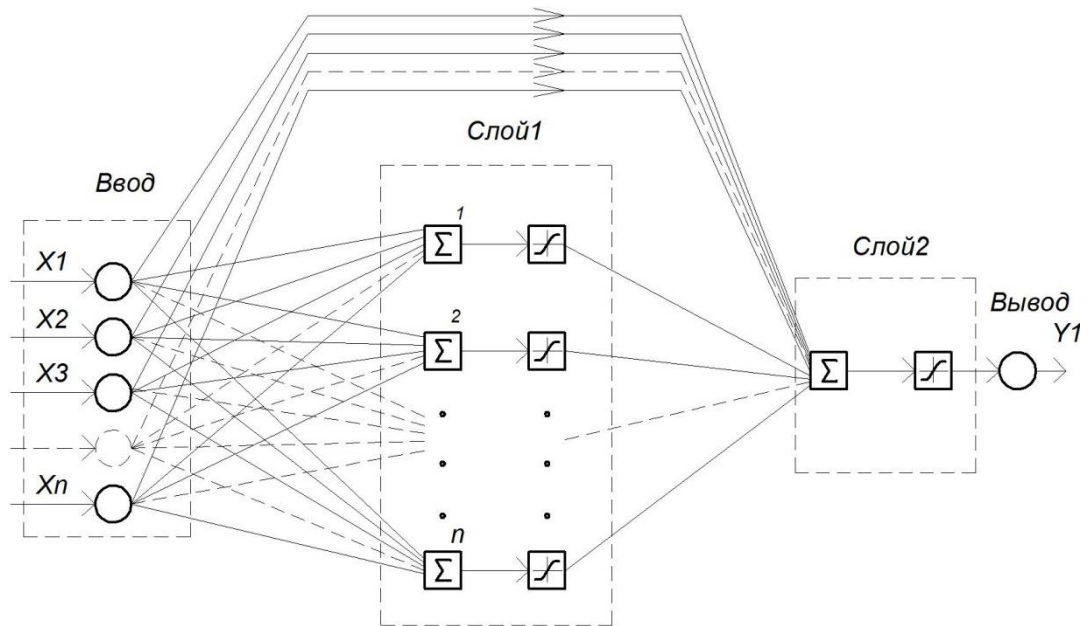


Рис.2.5. Схема нейронной сети каскадной корреляции

Каждый из шагов завершается, когда ошибка перестает уменьшаться. Добавление новых каскадов прекращается, когда суммарная ошибка сети достигнет максимально допустимого значения.

Рекуррентные нейронные сети имеют в своей структуре внутренние обратные связи. Эти связи организованы таким образом, что сигнал с выходных нейронов или нейронов скрытого слоя частично или полностью передается обратно на входы нейронов входного слоя. Обратными связями могут охватываться как отдельные слои, так и несколько слоев.

Обратные связи расширяют функциональные возможности рекуррентной сети благодаря тому, что имеются динамические зависимости на каждом этапе функционирования: изменение состояния одного нейрона отражается на всей сети.

Одним из распространённых видов рекуррентной сети является нейронная сеть Элмана. Данная сеть формируется на основе многослойного персептрона путем введения обратных связей (Рис.2.6).

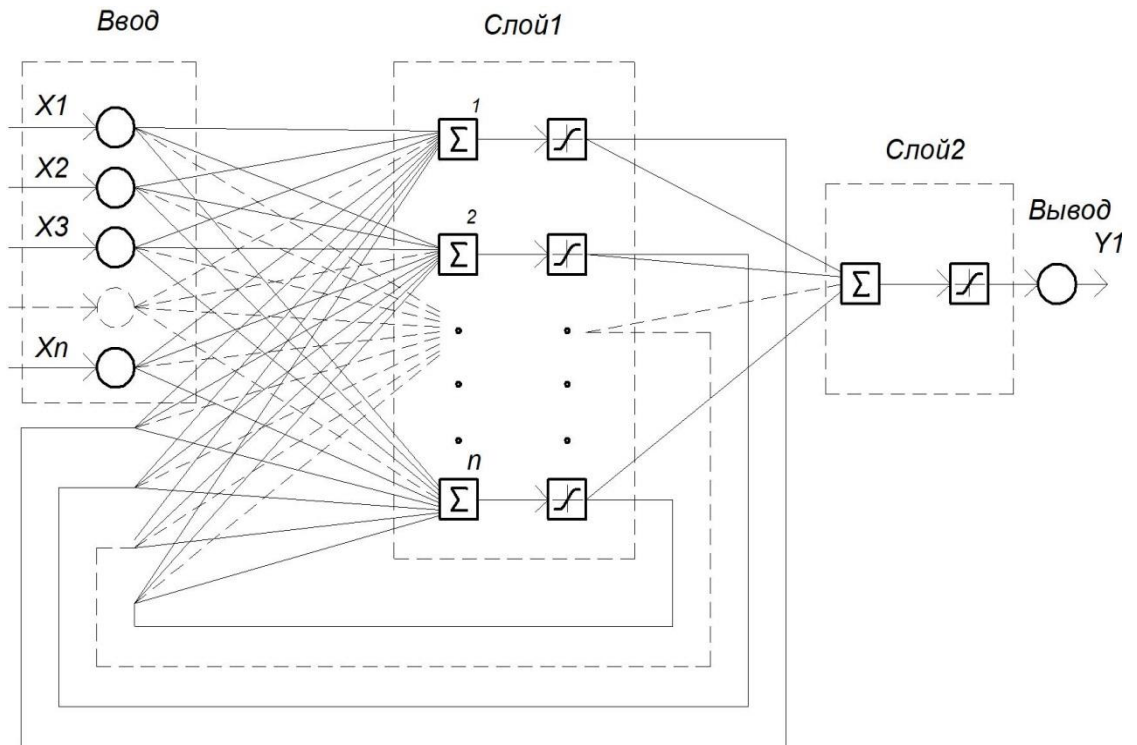


Рис.2.6. Схема нейронной сети Элмана

Основной особенностью данной нейросети является то, что связи идут с выхода сети и с выходов внутренних нейронов и поступают на дополнительные входы. Благодаря этому формируется контекст, который хранит информацию о предыдущем входном векторе в течении одной итерации. Следовательно, выходная переменная зависит не только от значений переменных текущей итерации, но и значений переменных предыдущей итерации [26]:

$$y = f \left(\sum_{i=1, j=1}^n x_i(k) w_j(k) + x_i(k-1) w_j(k-1) \right), \quad (2.32)$$

где $x(k-1)$, $w(k-1)$ – предыдущее состояние переменной и синаптического коэффициента.

За счет обратных связей нейросеть Элмана может распознавать и воспроизводить (восстанавливать) временные и пространственные образы. Эти сети широко применяются в системах прогнозирования, поскольку их особенностью является запоминание временных последовательностей.

Рассмотренные типы сети исследовались с одним скрытым слоем (трехслойные сети) и с двумя скрытыми слоями (четырёхслойные сети).

В Табл. 2.6 приведены результаты прогнозирования при использовании различных типов сетей.

Из анализа результатов прогнозирования следует, что для синтеза эффективных нейронных сетей необходимо использовать следующие типы трех и четырехслойных сетей:

- с прямым распределением;
- с прямым распределением и задержкой по времени;
- рекуррентные сети Элмана.

Табл. 2.6. Результаты прогнозирования различными типами ИНС

Название нейронной сети	Кол-во нейронов в скрытом слое	Плотность распределения погрешностей (количество и проценты)				СО СКО (%)
		0-3%	3-5%	5-10%	>10%	
Нейросеть с прямым распределением	75	497 69%	153 21.3%	58 8%	12 1.7%	2,58 3,66
Нейросеть с прямым распределением и задержкой по времени	75	509 70.7%	149 20.7%	50 7%	12 1.6%	2,44 3,59
Нейросеть с каскадным распределением	75	504 70%	151 21%	54 7.5%	11 1.5%	2,52 3,79
Нейросеть Элмана	75	573 79.6%	95 13.2%	46 6.4%	6 0.8%	2,00 2,75
Четырехслойная нейросеть с прямым распределением	35-30	516 71.7%	141 19.5%	51 7.1%	12 1.7%	2,39 3,62
Трехслойная нейросеть Элмана	35-30	534 74.1%	141 19.6%	33 4.6%	12 1.7%	2,33 3,52

При выборе трехслойной структуры важно не только количество нейронов в скрытых слоях, но и функция активации. Исследуем влияние вида функции активации и количества нейронов в скрытом слое на примере двухслойной

нейросети с прямым распределением. Результат этих исследований представлены в Табл. 2.7.

Табл. 2.7. Влияние вида функции активации

Количество нейронов	Функция активации	СО (%)	СКО (%)
10-10	Tansig-Tansig	1,818	2,20
30-20	Tansig-Tansig	1,851	2,55
30-30	Tansig-Tansig	2,06	2,82
40-35	Tansig-Tansig	1,74	2,26
10-10	Tansig-Purelin	2,69	3,45
20-10	Tansig-Purelin	1,87	2,40
35-30	Tansig-Purelin	2,00	2,50
40-35	Tansig-Purelin	1,87	2,29

В качестве примера на Рис.2.7 приведены графики почасового потребления реального и спрогнозированного для наиболее сложного периода – первых 24 январских дней.




Рис.2.7. Графики реального и спрогнозированного электропотребления за январь (нейронная сеть с прямым распределением и задержкой по времени: СО=1,89, СКО=2,36)

На основе проведенных исследований были синтезированы и отобраны по минимуму погрешностей прогнозирования 12 видов наиболее эффективных нейронных сетей (Табл. 2.8).

Табл. 2.8. Эффективные нейронные сети

ИНС	Кол-во нейронов в скрытых слоях	Плотность распределения погрешностей (количество и проценты)				СО СКО (%)
		0-3%	3-5%	5-10%	>10%	
Трехслойная ИНС Элмана	75	585 81.3%	95 13.2%	39 5.4%	1 0.1%	1,85 2,43
Четырехслойная Элмана (ДИНС Элмана)	40-35	519 72.1%	142 19.7%	55 7.6%	4 0.6%	2,22 2,94
Четырехслойная Элмана с линейной функцией активации (ДИНС Элмана с ЛФА)	35-30	557 77.5%	116 16%	44 6.1%	3 0.4%	2,05 2,68
Трехслойная ИНС с прямым распространением и задержкой по времени (ИНС с ПР и ЗВ)	75	571 79.3%	119 16.5%	30 4.2%	0 0 %	1,89 2,36
Четырехслойная с прямым распределением и задержкой по времени (ДИНС с ПР и ЗВ)	40-35	574 79.7%	118 16.4%	25 3.5%	3 0.4%	1,87 2,47
Четырехслойная с прямым распределением и задержкой по времени (ДИНС с ПР и ЗВ)	35-30	547 76%	128 17.8%	43 6%	2 0.2%	1,99 2,60
Трехслойная ИНС с каскадным распределением (ИНС с КР)	75	557 77.4%	128 17.8%	31 4.3%	4 0.5%	2,03 2,66
Четырехслойная с каскадным распределением (ДИНС с КР)	35-30	537 74.6%	124 17.2%	56 7.8%	3 0.4%	2,19 2,83

ИНС	Кол-во нейронов в скрытых слоях	Плотность распределения погрешностей (количество и проценты)				СО СКО (%)
		0-3%	3-5%	5-10%	>10%	
Трехслойная ИНС с прямым распределением (ИНС с ПР)	75	571 79.3%	113 15.2%	36 5%	0 0 %	1,87 2,41
Четырехслойная с прямым распределением (ДИНВ с ПР)	40-35	606 84.2%	82 11.4%	32 4.4%	0 0 %	1,74 2,27
Четырехслойная с прямым распределением (ДИНВ с ПР)	35-30	582/80.8	107/14.9	30/4.2	1/0.1	1,80 2,36
Четырехслойная с прямым распределением и с линейной функцией активации (ДИНВ с ПР и ЛФА)	40-35	570 79.2%	133 18.5%	17 2.3%	0 0 %	1,87 2,29

Результаты экспериментальных исследований эффективных нейронных сетей приведены в Приложении 1.

Для среднесрочного прогнозирования от недели до месяца прогнозирование осуществлялось путем прогнозирования отдельно по дням недели и затем суммирования потребления за 7, 28, 30 или 31 суток (см. раздел 2.5). Экспериментально определено, что наиболее эффективными являются нейронные сети с прямым распределением и задержкой по времени. Выбор таких ИНС обусловлен тем, что, как уже отмечалось, данные ИНС позволяют определять нелинейные зависимости между переменными на основе больших массивов и обладают наибольшей универсальностью.

Результаты прогнозирования и получаемые погрешности при использовании обучающей выборки за пять лет представлены в Табл. 2.9. Таким образом, объем обучающей выборки составляет примерно 1800, что почти в 5 раз меньше, чем при

краткосрочном прогнозировании. Поэтому нейронная сеть в закрытом слое имеет 25 нейронов.

Табл. 2.9. Прогнозирование на неделю вперед

Число	Реальное потребление, кВт*ч	Прогнозное потребление, кВт*ч	Абсолютная погрешность, кВт*ч	СО (%)
09.03.2019	5623787	6095541	-471754	8,39
10.03.2019	5981783	6196210	-214427	3,58
11.03.2019	5937830	6085488	-147658	2,49
12.03.2019	5981945	6097206	-115261	1,93
13.03.2019	5978421	6195618	-217197	3,63
14.03.2019	5530996	5808598	-277602	5,02
15.03.2019	5365329	5473402	-108073	2,01
Средняя величина СО (%)				3,86
16.03.2019	5908630	5969998	-61368	1,04
17.03.2019	5874216	6032558	-158342	2,70
18.03.2019	5820361	5977979	-157618	2,71
19.03.2019	5791660	5890241	-98581	1,70
20.03.2019	5788720	5837975	-49255	0,85
21.03.2019	5521361	5568191	-46830	0,85
22.03.2019	5418264	5387668	30596	0,56
Средняя величина СО (%)				1,49
23.03.2019	6017608	6150664	-133056	2,21
24.03.2019	6210980	6026462	184518	2,97
25.03.2019	6088158	5974214	113944	1,87
26.03.2019	6039157	5894131	145026	2,40
27.03.2019	6028558	5856207	172351	2,86
28.03.2019	5704399	5576105	128294	2,25
29.03.2019	5548009	5303142	244867	4,41
Средняя величина СО (%)				2,71

Из Табл. 2.9 следует, что средняя ошибка недельного прогнозирования, определяемого суммированием суточных прогнозов, изменяется в диапазоне от 1,5% до 4%. В среднем за три недели СО = 2,71%. Полученные результаты можно оценить, как удовлетворительные, но требующие дальнейшего улучшения потому,

что одно и та же нейронная сеть, например, для 09.03.2019 дает прогноз с погрешностью более 8%, для 22.03.2019 прогноз имеет погрешность 0,56%. Следовательно, требуется применение различных типов нейронных сетей и объединение их в ансамбль.

Был также исследован тот же метод прогнозирования на месяц с помощью нейронных сетей с прямым распределением и задержкой по времени путем прогнозирования отдельно по дням недели и затем их суммирования.

Результаты прогнозирования на месяц при использовании обучающей выборки за пять лет представлены в Табл. 2.10.

Табл. 2.10. Прогнозирование на месяц вперед

Данные взяты по 31 день	Реальное потребление, кВт*ч	Прогнозное потребление, кВт*ч	Абсолютная погрешность, кВт*ч	СО (%)
Февраль	262917493,63	256156672,00	6760821,62	2,64
Март	252047066,33	245492542,49	6554523,84	2,67
Апрель	227645259,45	222926617,76	4718641,69	2,12
Май	200246490,65	194851678,33	5394812,32	2,77
Июнь	188986324,26	198149609,23	-9163284,97	4,62
Июль	187520844,03	191714564,51	-4193720,48	2,19
Август	199215285,97	200026232,21	-810946,24	0,41
Сентябрь	215067421,08	224290143,61	-9222722,53	4,11
Октябрь	235080095,06	231713447,78	3366647,28	1,45
Ноябрь	251882558,44	254406214,64	-2523656,20	0,99
Декабрь	267118876,65	263515967,08	3602909,57	1,37
Январь	268369314,7	271171496,9	-2802182,19	1,04

Результаты долгосрочного прогнозирования на год вперед, которое осуществляется с помощью суммирования помесечных прогнозов на основе рассмотренного выше входного вектора по данным Табл. 2.10. представлены на Рис.2.8, где указаны точки ежемесячного потребления и точки графика прогнозов.




Рис.2.8. Графики реального и прогнозного электропотребления, построенные по точкам ежемесячного потребления

За счет усреднения отдельных прогнозов среднегодовой прогноз имеет, как представлено в Табл. 2.11, более высокую точность.

Табл. 2.11. Помесячное прогнозирование электроэнергии на год

Реальное потребление, кВт*ч	2 495 930
Спрогнозированное потребление, кВт*ч	2 512 924
Абсолютная погрешность, кВт*ч	-16 994
Относительная погрешность, (%)	0,68

Второй способ получения прогнозирования на год вперед осуществлялся путем суммирования посуточных прогнозов за 365 суток, при этом входной вектор определяется выражением (2. 25). Такой способ дает, как представлено в Табл. 2.12, еще более высокую точность. При этом наиболее эффективной оказалась трехслойная нейронная сеть прямого распространения.

Табл. 2.12. Результаты прогнозирования на год вперед

Реальное потребление, кВт*ч	2871423717
Спрогнозированное потребление, кВт*ч	2864532300
Абсолютная погрешность, кВт*ч	-6891417
Среднее отклонение (СО%)	0,14

На Рис.2.9 представлены графики реального и прогнозного годового электропотребления путем усреднения посуточного потребления.

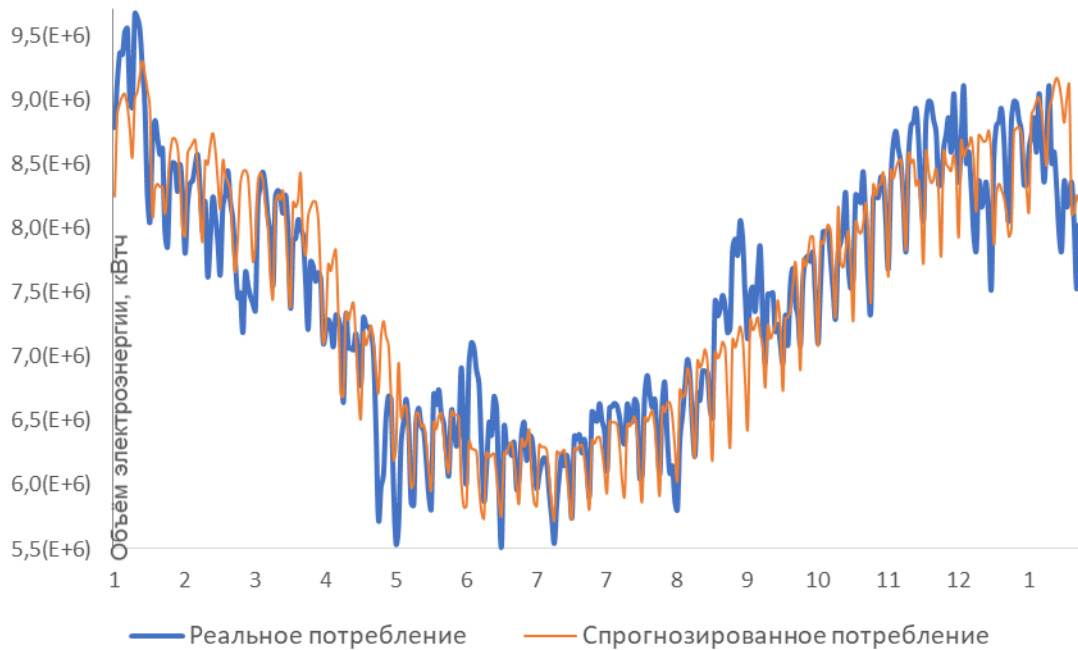


Рис.2.9. График посуточного прогнозирования потребления электроэнергии на год

Из проведенных исследований следует вывод, что полученные результаты находятся на приемлемом уровне и разработанные нейросетевые модели прогнозирования могут с успехом использоваться в различных системах управления режимами работы сетей, для оптовых закупок электроэнергии и расчета тарифов. Тем не менее необходим дальнейший поиск повышения точности прогнозирования и универсальности к графикам потребления. Очевидно, усовершенствование моделей прогнозирования при использовании только одиночной нейронной сети не приведет к заметным улучшениям. Как было доказано выше, повышение точности прогнозирования и достижение универсальности прогнозной модели можно достичь системным применением синтезированных нейронных сетей путем объединения их в ансамбли или комитеты.

2.6. Выводы по главе 2

1. Проведено исследование аппроксимирующих свойств многослойных нейронных сетей, чтобы определить методику их синтеза и формирования на их основе ансамблей. С этой целью получены в развернутом и векторном виде

выражения, определяющие функциональную связь между входными и выходными переменными сети. Данные выражения согласуются с теоремой А.Н. Колмогорова, в соответствии с которой функцию многих переменных можно представить в виде сложения и суперпозиции непрерывных функций одной переменной. Однако определение этих функций связано с принципиальными трудностями. Поэтому целесообразно, используя теорему Стоуна-Вейерштрасса, которая доказывает, что любую функцию многих переменных можно аппроксимировать со сколь угодно малой погрешностью с помощью линейной комбинации функционального ряда смещенных и монотонно ограниченных функций, представлять нейронную сеть как универсальный «аппроксиматор» в форме функционального ряда. При заданных функциях активации обучение нейронной сети, как и в линейном случае, сводится к определению оптимальных значений весовых коэффициентов по минимуму среднеквадратичной ошибки. Для этого достаточно, чтобы нейронная сеть имела не менее трех слоев с сигмоидальными функциями активации в скрытом слое.

2. Для определения эффективности нейронных сетей, получаемых в результате их синтеза, расширен набор оценочных показателей. С учетом требований к системам управления электропотреблением для оценки погрешности прогнозирования наряду с общепринятыми показателями – среднее и среднеквадратичное отклонение, предложено применять по аналогии с плотностью вероятности такой показатель, как плотность распределения погрешностей прогнозирования. Численно плотность распределения погрешностей определяется как количество прогнозов или их процент, погрешность которых находится в определенных интервалах 0-3%, 3-5%, 5-10%. На основе интервальных оценок, в свою очередь, получена шкала допустимых усредненных погрешностей прогнозирования.

3. Определен состав входного вектора или набора факторов, по которым осуществляется прогнозирование электропотребления. На основе системного подхода множество возможных значимых факторов декомпозировано в виде системы трех подмножеств: статических переменных, которые несут информацию

о моменте времени прогнозирования; динамических переменных, представляющих ретроспективные данные потребления; уточняющих факторов, определяющих особенности графиков потребления.

4. Установлено, что подмножество статических переменных должно формироваться в зависимости от вида прогноза: для краткосрочного оно должно состоять из идентификаторов часа, дня недели и месяца; для среднесрочного и долгосрочного – из идентификаторов дня недели, дня месяца и месяца. Выявлено, что для краткосрочного прогнозирования дополнительным усовершенствованием входного вектора является дублирование идентификаторов часа в соответствии с количеством ретроспективных данных о почасовом потреблении электроэнергии.

5. С помощью метода авторегрессионной аппроксимации определено, что для формирования динамических переменных для краткосрочного прогнозирования достаточно использовать ретроспективные данные почасового потребления не более чем на пять суток; для среднесрочного прогнозирования на неделю вперед – данные посуточного потребления электроэнергии со сдвигом на пять недель; для среднесрочного прогнозирования на месяц вперед – данные посуточного потребления электроэнергии с ретроспективой на месяц; для долгосрочного прогнозирования на год вперед – данные помесечного или посуточного потребления при объеме обучающих выборок за пять лет.

6. Нейросетевая модель краткосрочного прогнозирования наиболее чувствительна к особенностям графиков почасового потребления электроэнергии. Для идентификации этих особенностей входной вектор дополняется подмножеством уточняющих факторов, в состав которого включены идентификаторы особенности дневных режимов работы. В то же время доказано, что возможно прогнозирование потребления электроэнергии с необходимой точностью без использования таких ненадежных факторов, как прогнозные данные по метеоусловиям.

7. В результате сформированы минимальные входные векторы: для краткосрочного – 13-размерный вектор при использовании 9 переменных; для

среднесрочного – 7-размерный (прогноз на неделю вперед) и 4-размерный (прогноз на месяц вперед); для долгосрочного прогнозирования – 4-размерный.

8. Для определения состава структуры эффективных нейронных сетей определялось соотношение между объемом обучающей выборки и числом настраиваемых коэффициентов трехслойной нейронной сети. По критерию способности нейронной сети к обобщению применялась мера Вапника - Червоненкиса. Установлено, что общее число обучающих выборок должно превышать эту меру в 2-3 раза, для чего требуется данные электропотребления, как минимум, за два предыдущих года. В результате получено, что структуры синтезированных нейронных сетей отличаются тем, что число нейронов в скрытых слоях, в несколько раз превышает количество нейронов во входном слое. Избыточное число нейронов позволяет аппроксимировать различные, даже очень сложные графики потребления электроэнергии, чем обеспечивается применимость синтезированных систем прогнозирования к различным графикам нагрузки.

9. Выявлены особенности методики обучения синтезированных нейронных сетей. На контрольном подмножестве осуществляется проверка на насыщение, когда объем обучающей выборки превосходит сложность нейросети. С помощью тестового множества методом раннего останова предотвращается эффект «переобученности» нейросети.

10. Основываясь на проведенном исследовании аппроксимирующих свойств нейронных сетей и экспериментальных результатах прогнозирования установлено, что для синтеза эффективных нейронных сетей необходимо использовать следующие базисные типы трех и четырехслойных сетей: с прямым распределением; с прямым распределением и задержкой по времени; рекуррентные сети Элмана.

11. На основе этих базисных типов были синтезированы, экспериментально исследованы и отобраны по минимуму погрешностей прогнозирования 12 видов наиболее эффективных нейронных сетей, которые могут служить основой для формирования ансамблей для дальнейшего повышения

точности и обеспечения универсальности систем прогнозирования потребления электроэнергии.

12. Для среднесрочного прогнозирования на неделю и месяц вперед эффективными являются нейронные сети с прямым распределением и задержкой по времени. Объем обучающей выборки формируется из ретроспективных данных за 5 лет, что составляет 1800. Это почти в 5 раз меньше, чем при краткосрочном прогнозировании. Поэтому нейронная сеть в закрытом слое имеет 25 нейронов. Средняя ошибка прогнозирования изменяется в диапазоне от 1,5% до 4%. В среднем за три недели $CO = 2,71\%$ Полученные результаты можно оценить, как удовлетворительные, но требующие дальнейшего улучшения с помощью применения ансамбля нейронных сетей.

13. Погрешность долгосрочного прогнозирования на год вперед, которое осуществляется с помощью суммирования помесечных прогнозов, составляет 0,68%, а с помощью суммирования 365 суточных прогнозов составляет 0,14%. Таким образом, для долгосрочного прогнозирования достаточно применения единичной нейронной сети.

ГЛАВА 3. МЕТОДИКА ФОРМИРОВАНИЯ АНСАМБЛЕЙ НЕЙРОННЫХ СЕТЕЙ ДЛЯ СИСТЕМ ПРОГНОЗИРОВАНИЯ

3.1. Принципы работы и классификация ансамблей нейронных сетей

Так как одиночные ИНС не обладают необходимой универсальностью по отношению к видам прогнозов и особенностям графиков потребления электроэнергии то, в соответствии с выдвинутой в разделе 1.4 гипотезой, необходимо объединение различных типов нейронных сетей в ансамбли или комитеты. Обзор способов построения ансамблей показал, что они применяются, как правило, в тех случаях, когда требуется решить задачи классификации и регрессии для больших объемов данных и ансамбли организуются из «слабых» нейронных сетей. Спецификой решаемой задачи является то, что прогнозирование электропотребления производится по ограниченному объему обучающих выборок, поэтому формировать ансамбли необходимо из эффективных нейронных сетей, т.е. сетей, обеспечивающих прогнозирование с минимально возможной погрешностью.

На основе анализа аппроксимирующих свойств нейронных сетей сформулирована концепция синтеза структуры ансамбля. Ансамбль должен иметь иерархическую структуру, состоящую из эффективных нейронных сетей, отобранных таким образом, чтобы их выходы (отдельные прогнозы) имели минимальную корреляцию и обеспечивали максимально возможную взаимную компенсацию погрешности отдельных прогнозов с помощью нейросетей следующего уровня. Выходные сигналы нейросетей нижнего уровня представляют собой метаданные, на которых обучаются нейросети следующего уровня иерархии. Формируемые таким образом мета алгоритмы должны обеспечить повышение точности прогнозирования. В Главе 2 проведен результаты синтеза таких нейросетевых моделей, необходимых для формирования ансамблей.

Для определения наиболее рациональных способов реализации предлагаемой концепции проведен анализ публикаций, посвященных ансамблям нейронных сетей [73-86]. Классификация принципов работы ансамблей, представленная на Рис.3.1.

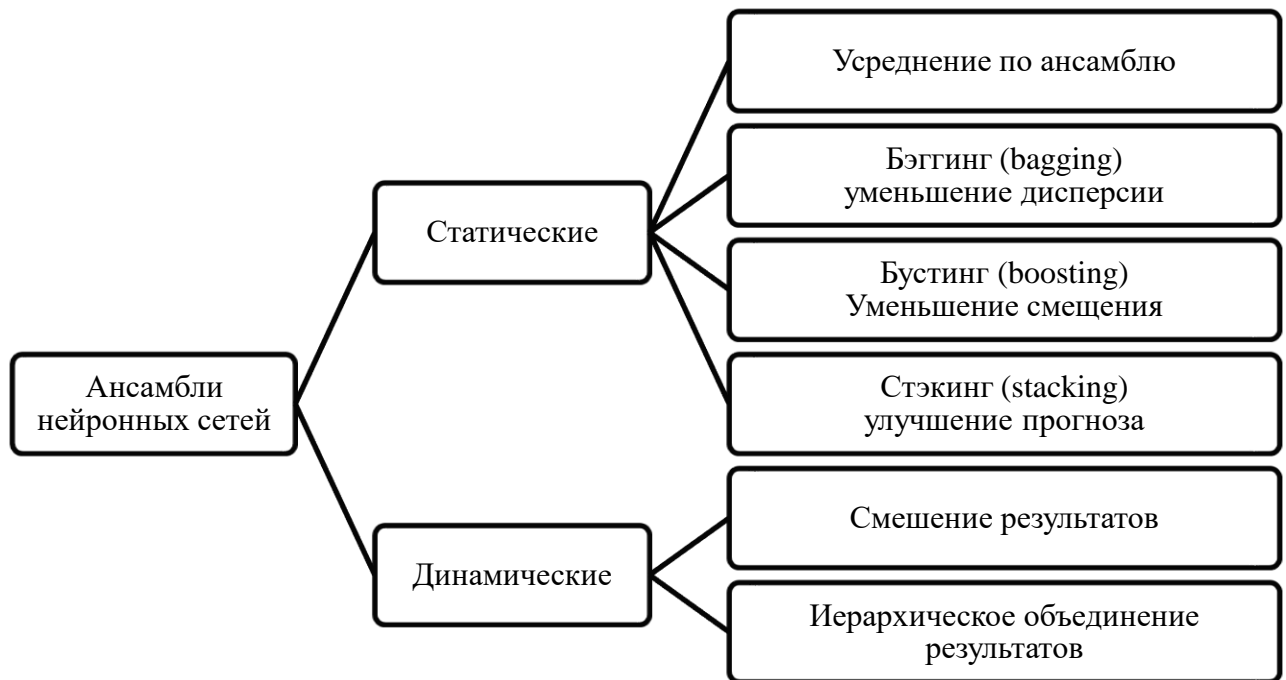


Рис.3.1. Классификация принципов работы ансамблей нейронных сетей.

Для статических ансамблей характерно объединение результатов прогнозирования отдельных нейронных сетей, входящих в их состав, без учета входного сигнала. В данной категории можно выделить четыре основных метода получения итогового прогноза.

Метод усреднения по ансамблю основан на линейной комбинации выходных сигналов, входящих в состав ансамбля нейронных сетей [75]. Применение такого метода может быть целесообразно, если каждая отдельная нейронная сеть, входящая в ансамбль, имеет более простую архитектуру, чем сеть, способная заменить весь ансамбль [76]. К тому же у такой сети со сложной внутренней архитектурой есть риск появления неполной обученности, которая может возникнуть вследствие того, что размер обучающей выборки может быть недостаточным. Одним из методов объединения прогнозов является простое усреднение [77]:

$$y(x) = \frac{1}{T} \sum_{g=1}^T y_g(x), \quad (3.1)$$

где $x = (x_1, x_2, \dots, x_k)$ – входной вектор;

k – число входов нейронной сети;

$y(x) = (y_1, y_2, \dots, y_n)$ – вектор прогнозов от нейронных сетей первого уровня, полученных как результат обработки входного вектора;

n – количество выходных сигналов нейронной сети;

T – количество нейронных сетей первого уровня ансамбля.

Данный метод прост в реализации и имеет низкую вычислительную сложность. Его основной недостаток состоит в том, что при ограниченном числе нейронных сетей их погрешности из-за корреляции отдельных прогнозов чаще всего не компенсируются, а усиливают друг друга. Экспериментально это подтверждается результатами, приведенными в Табл. 3.1.

Другим способом объединения прогнозов является использование взвешенной суммы:

$$y(x) = \sum_{g=1}^T k_g y_g(x), \quad (3.2)$$

где k_g – коэффициент веса g -той нейронной сети первого уровня.

Недостатком этого способа является зависимость результата от правильного определения коэффициентов веса отдельных нейросетей. Для устранения этого недостатка и для уменьшения дисперсии погрешностей необходимо использовать корректировку пропусков данных, обнаружение аномальных значений, обработку дубликатов и противоречий и другие алгоритмы анализа данных. Но этого недостаточно, необходимо еще определять оптимальные значения k_g , например, по минимуму результирующей погрешности прогнозирования [78].

Следующий тип структуры ансамбля – *бэггинг*, имеющий много общего с предыдущим типом. Ансамбль формируется параллельным методом, но на основе слабых, как правило, однородных нейронных сетей, настроенных независимо друг от друга с последующим объединением их результатов. Данный способ относится к стохастическим [85,86]. Основные сети настраиваются (обучаются) на случайно выбранных подмножествах обучающей выборки. Результаты прогнозирования обученных нейронных сетей объединяются в ансамбль путем простого или взвешенного голосования. Таким образом, при формировании ансамбля по алгоритму бэггинга, исходные данные случайно разбиваются на одинаковые по

размеру подмножества, каждое из которых используется для обучения однородных нейронных сетей. Прогноз ансамбля определяется усреднением результатов.

Данный метод требует большого объема обучающей выборки и дополнительных вычислительных затрат, связанных с необходимостью формирования подмножеств из обучающей выборки, которая должна иметь достаточно данных для настройки и обучения всех компонентов ансамбля. В связи с тем, что подмножества формируются случайно, одни примеры могут присутствовать несколько раз, а другие ни разу.

В ансамбле, имеющему структуру *бустинга* нейронные сети обучаются последовательно. Набор данных, на которых обучается каждая последующая нейронная сеть, зависит от точности прогнозирования предыдущей нейронной сети. Это реализуется за счет фильтрации или перевзвешивания [83-87]. Принцип работы такого алгоритма заключается в следующем. Первая нейронная сеть обучается на первом подмножестве, состоящем из N примеров. С помощью этой обученной сети формируется второе подмножество из N примеров, на которых эта сеть в 50% дает безошибочный прогноз. Затем на отобранных таким образом примерах обучается вторая нейронная сеть. После этого обучается третья нейронная сеть также на N примерах, но выбранных из условия, что на данных примерах прогнозы первой и второй нейронных сетей расходятся. За результирующие прогнозы берутся прогнозы, выдаваемые первыми двумя сетями, если эти прогнозы совпадают. В противном случае берется прогноз третьей сети. Повышение эффективности (усиление) качества прогнозов обеспечивается тем, что при вероятности получения ошибки прогнозов, равной q , каждой сетью в отдельности, результирующая ошибка при формировании выходного сигнала рассмотренным способом уменьшается в соответствии с выражением:

$$3q^2 - 2q^3 < q.$$

Количество объединяемых нейронных сетей может быть достаточно большим. Их обучение должно проводиться также последовательно, но при этом уменьшается размер обучающих выборок для каждой сети. Можно обучать все сети на одной и той же выборке, но необходимо применять весовые коэффициенты,

изменяющиеся в течение времени в соответствии с её влиянием на обучение нейронной сети (см. Рис.3.2).

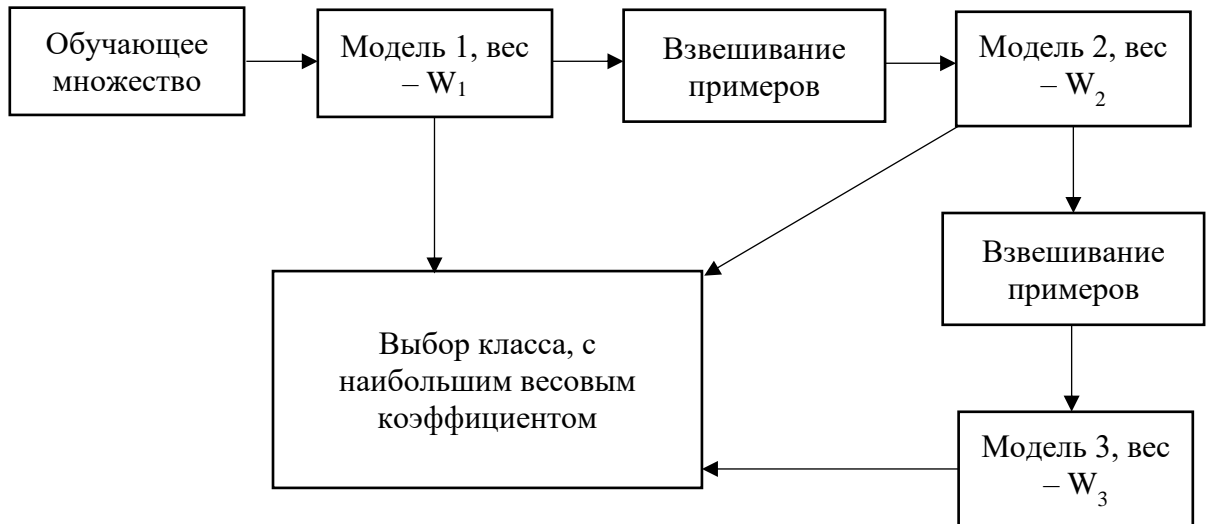


Рис.3.2. Схема построения ансамбля с использованием перевзвешивания

Ограниченность этого метода очевидна, так как он требует большой объем обучающей выборки, значительных вычислительных ресурсов, и в процессе обучения может произойти потеря различных частей первоначальной выборки из-за особенности функционирования данного алгоритма. В частности, затруднительно признать окончательно, что поняты все принципы повышения точности прогнозирования. Нет ясных, оцениваемых одновременно с обучением, критериев выбора вида числа нейронных сетей, при этом минимальный объем обучающей выборки определяется величиной порядка $10^4 - 10^6$.

При структуре типа стэкинга нейросети объединяются в ансамбль с использованием множества уровней [83,87]. Чтобы ансамбли были более точными, чем любая отдельная сеть, базовые нейронные сети должны быть максимально различными [88]. Все выбранные нейронные сети образуют базовый уровень, результаты которого (метаданные) подаются на вход второго уровня. Обучающая выборка делится на две части. На одной части обучаются сети базового уровня. Затем, на обученные нейросети подается вторая выборка. Полученные при этом выходные сигналы с нейронных сетей первого уровня подаются на второй уровень, играющий роль внешнего мета алгоритма. Этот мета алгоритм настраивается на второй части обучающей выборки, чтобы исключить переобучение. Недостатком

такого ансамбля являются меньшие объемы данных, используемые для обучения базовых и мета алгоритмов и, как следствие, более низкое качество работы, чем при обучении на всех данных. Также требуется определить пропорцию разбиения обучающей выборки на две или более частей в зависимости от количества уровней иерархии ансамбля. Особую проблему представляет выбор вида мета алгоритмов. Если для реализации такого алгоритма использовать также нейронную сеть, то, в принципе, получаем ансамбль в виде многослойной нейронной сети. Но в отличие от стэкинга, одиночная нейронная сеть обучается по всем параметрам. В случае применения ансамбля этот процесс декомпозируется на обучение отдельных нейронных сетей.

Динамические ансамбли выдают прогноз с учетом входного сигнала, объединяя его с выходными сигналами, входящими в состав ансамбля нейронных сетей. При создании динамических ансамблей используется 2 основных подхода [88-90]:

- смешение прогнозов – результаты прогнозирования отдельных нейронных сетей нелинейно объединяются в единую шлюзовую сеть (см. Рис.3.3). Шлюз – это элемент, определяющий нейронную сеть, которая сможет оптимально обработать текущий входной вектор;

- иерархическое объединение прогнозов – результаты прогнозирования отдельных нейронных сетей. Они нелинейно объединяющихся при помощи нескольких шлюзовых сетей, выстроенных в иерархическую структуру, аналогично первому варианту, но с применением иерархической структуры и нескольких сетей шлюзов.

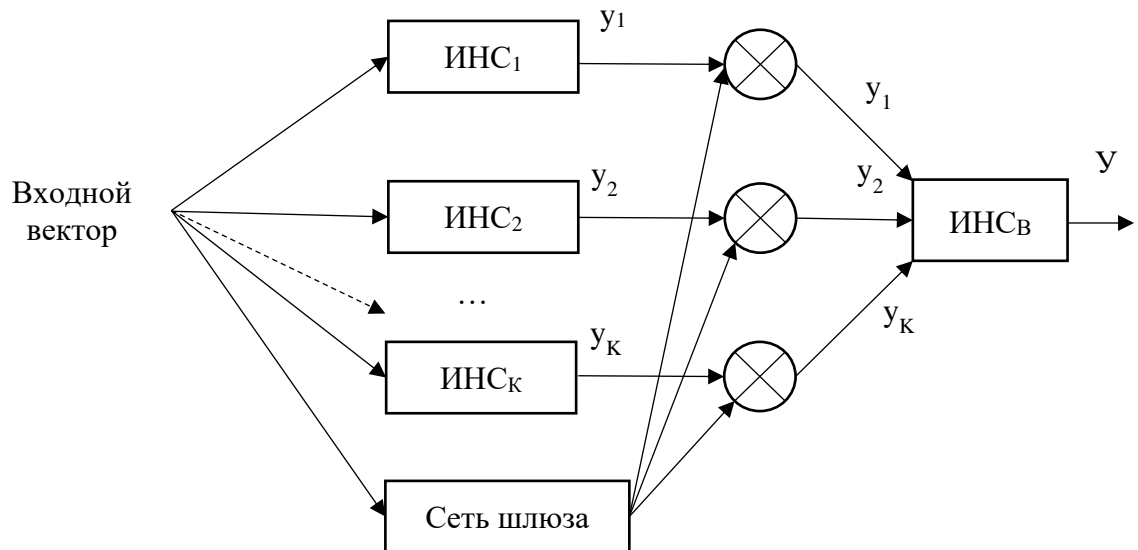


Рис.3.3. Ансамбль, построенный на базе смешения прогнозов

Каждый из рассмотренных методов объединения нейронных сетей в ансамбли или комитеты имеет определенные достоинства и недостатки, и области их применения определяется спецификой решаемых задач. Поэтому целесообразность применения ансамбля какой-либо архитектуры требует самостоятельного исследования.

3.2. Методика формирования ансамбля из эффективных нейронных сетей

Из анализа существующих методов построения ансамблей следует, что предложенная концепция построения ансамбля из эффективных нейронных сетей занимает промежуточное положение между методом стэкинга и динамическим методом смешения прогнозов [91, 92].

В таких ансамблях прогнозируемая величина формируется мета алгоритмом в виде функции от метаданных (3.3):

$$y(x) = F(y_1(x), y_2(x), \dots, y_T(x)), \quad (3.3)$$

где: $y_i(x)$ – данные, выдаваемые предшествующим уровнем иерархии;

F – функция, определяющая результирующий прогноз.

На Рис.3.4 представлен в общем виде трехуровневый ансамбль, реализующий предлагаемую концепцию. Такой ансамбль, по существу, совмещает функции взвешенного суммирования, стэкинга, смешения прогнозов и их иерархическое объединение, поэтому имеет в потенциале наибольшую универсальность.




Рис.3.4. Иерархическая структура ансамбля ИНС

В первый уровень иерархии входит k различных нейронных сетей, на вход которых одновременно подается входной вектор обучающей выборки, а с выхода снимаются прогнозные значения электропотребления.

Нейронные сети первого уровня ансамбля обучаются на всех ретроспективных данных по методике, описанной в предыдущей главе. В результате согласно выражению (2.3) на выходе i -той нейронной сети будет формироваться сигнал:

$$y_{1i}(\mathbf{x}) = f_{1i}^b \left(\mathbf{v}_{1i}^T f_{1i}^a(\mathbf{w}_{1i}\mathbf{x}) \right). \quad (3.4)$$

Нейронные сети второго уровня ансамбля, количество l которых меньше, чем нейронных сетей первого уровня ($l < k$) обучаются так же, как и сети первого уровня. Входным вектором для них является множество выходных значений (метаданные) сетей первого уровня:

$$\mathbf{y}_1 = [y_{11}, y_{12}, \dots, y_{1k}]^T.$$

Сети последующих уровней обучаются аналогично. Для них входной вектор также формируется из выходных сигналов сетей предыдущего уровня.

$$y_{2i}(\mathbf{y}_1) = f(y_{11}, y_{12}, \dots, y_{1k}) = f_2^b \left(\mathbf{v}_2^T f_2^a(\mathbf{w}_2\mathbf{y}_1) \right)$$

где y_{1k} – выходы с 1 по k нейронных сетей первого уровня ансамбля.

Подставляя в это выражение зависимости для $y_{1i}(\mathbf{x})$ получим:

Как указывалось, для исключения эффекта переобученности нейронных сетей, каждый уровень ансамбля должен обучаться на своей выборке данных электропотребления и при обучении на одной и той же выборке во всех уровнях иерархии используются одинаковые целевые векторы.

По мере продвижения по уровням иерархии размерность входного вектора уменьшается, так как в качестве входных переменных берутся метаданные, представляющие выходные сигналы нейронных сетей предыдущего уровня иерархии. Это приводит к упрощению структуры нейронных сетей, т.е. к уменьшению количества настраиваемых синаптических связей. Поэтому для обучения нейронных сетей второго и третьего уровней достаточно данных тестирующего подмножества T . Таким образом, нейронные сети первого уровня и нейронные сети второго и третьего уровней обучаются на разных выборках, что является дополнительной страховкой от переобучения и увеличения корреляции метаданных.

Для практического построения ансамбля необходимо решить следующие основные задачи:

- какие типы нейронных сетей необходимо применять для каждого уровня;
- сколько нейронных сетей должен иметь каждый уровень иерархии;
- сколько необходимо уровней иерархии.

Методика решения данных задач представлена в следующем разделе.

3.3. Метод выбора нейронных сетей для формирования системы прогнозирования в виде ансамбля

Первоочередной задачей при формировании системы в виде ансамбля искусственных нейронных сетей (АИНС) является определение типа и количества нейронных сетей первого уровня, которые формируют метаданные для второго уровня ансамбля. Возможны два принципиально разных подхода. Первый заключается в использовании на первом уровне нейронных сетей, максимально отличающихся по типу: например, многослойный персептрон, радиально-базисная сеть, нечеткая нейронная сеть и т.д. Это делается для того, чтобы обеспечить наименьшую корреляцию метаданных и наиболее адаптивное прогнозирование

при разных свойствах аппроксимируемой зависимости. Но при этом надо определить весовую значимость метаданных, что является трудно разрешимой задачей.

Второй подход заключается в использовании на базовом (первом) уровне однотипных нейронных сетей с избыточной сложностью. За счет избыточной сложности выходные сигналы этих сетей (метаданные) имеют большую дисперсию. Но при объединении достаточного числа (более десяти) этих метаданных происходит взаимная компенсация разбросов отдельных сигналов. Несмотря на это, результирующий прогноз такого ансамбля не превышает по точности одиночную сеть. Упрощается лишь процедура формирования прогнозирующей системы в виде ансамбля по сравнению с поиском оптимальной архитектуры одной нейронной сети. Поэтому базовый уровень должен формироваться из разнотипных и эффективных нейронных сетей, дающих минимальные погрешности прогнозирования энергопотребления [93].

Для проверки этой гипотезы базовый уровень АИНС был сформирован из 12 наиболее эффективных нейронных сетей, приведенных в Табл.2.8. Для нахождения результирующего прогноза применен метод усреднения с помощью взвешенной суммы (см. (3.2)). С целью определения весовых коэффициентов на втором уровне ансамбля применена линейная сеть, которая обучается по минимуму ошибки методом обратного распространения ошибки.




Рис.3.5. Двухуровневый ансамбль из 12 наиболее эффективных нейросетей

Результаты, приведенные в Табл. 3.1, показывают, что выходной прогноз имеет значительную дисперсию, т.е. рассмотренный АИНС ухудшил качество прогнозирования.

Табл. 3.1. Двухуровневый ансамбль из 12 нейросетей на первом уровне

Ансамбль нейронных сетей	Плотность распределения погрешностей прогнозирования (количество и проценты)				СО СКО
	0-3%	3-5%	5-10%	> 10%	
Первый уровень: показатели отдельных 12 нейронных сетей (Табл. 2.68)	50 - 84	11 - 22	2 - 24	0 - 4	1,7 - 2,4 2,3 - 2,8
Второй уровень: линейная нейросеть	37,5	26,2	29,8	6,5	3,8 4,7

Это объясняется тем, что при таком количестве нейронных сетей на первом уровне ансамбля некоторые метаданные сильно коррелированы, т.е. попадают на нейронные сети с подобными прогнозными графиками нагрузки (совпадают пики и провалы). Нейронная сеть на втором уровне ансамбля эти погрешности воспринимает как истинные значения благодаря их повторяемости. Следовательно, в соответствии с предложенной концепцией, необходимо так подобрать нейронные сети, чтобы их выходные сигналы (или метаданные) имели минимальную корреляцию и обеспечивали взаимную компенсацию погрешности отдельных прогнозов. Т.е. необходимо проводить выбор нейронных сетей более детально. Для этого предлагается использовать два, в определенном смысле противоречивых условия: минимально возможная погрешность аппроксимации или прогнозирования и максимальная возможность взаимной компенсации ошибок прогнозирования [94].

Экспериментально определено, что по точности прогнозирования нейронные сети должны иметь следующие показатели:

- среднее отклонение СО должно быть не более 2%;
- среднеквадратичное отклонение СКО – не более 2,5%;
- количество ошибок единичных прогнозирования, входящих в интервал

$\Delta_i \leq 3\%$, должно быть более 70%;

- количество ошибок прогнозирования, входящих в интервал $\Delta_i > 10\%$ должно быть минимальным (0-4%).

Данные показатели должны обеспечиваться на достаточно представительной выборке графика электропотребления – календарный год (365 дней или 8760 значений при почасовом прогнозе). В этом случае будут учтены все возможные виды графиков нагрузки. Сократить длину выборки можно, применив принцип максимального подобия. Для этого в годовом графике электропотребления надо выбрать максимально подобные периоды нагрузки, которые могут встречаться в прогнозируемом интервале времени. Такие периоды включают в себя все праздничные дни, а также одну из недель каждого месяца. В этом случае общее число выборки уменьшится до 2400 значений. Минимально необходимый объем выборки равен одному месяцу. При среднесрочном и долгосрочном прогнозированиях тестовые объемы выборок определяются из условия охвата всех типичных видов графиков электропотребления.

Как уже отмечалось, метаданные должны быть не коррелированы. Для такой оценки коэффициенты корреляции, например, коэффициент Пирсона, мало пригодны из-за их слишком усредненного характера. Более точными показателями возможности взаимной компенсации ошибок прогнозирования объединяемых нейронных сетей могут служить графики точечных погрешностей. С этой целью выявим ситуации, при которых происходит компенсация или наоборот увеличение ошибок прогнозирования от двух нейросетей [94].

На Рис.3.6 представлены возможные варианты взаимного положения погрешностей прогнозирования.

Как видно из Рис.3.6, возможно возникновение следующих ситуаций взаимного положения величин погрешностей прогнозирования двух нейронных сетей А и В:

- погрешности прогнозирования противоположны по знаку: т. А1 и В1 (наиболее благоприятная ситуация);

- погрешности прогнозирования одного знака, но отличается по величине: т. А2 и В2, а также т. А3 и В3 (промежуточная ситуация);
- погрешности прогнозирования одного знака и близки по величине: т. А4 и В4, а также т. А5 и В5 (наиболее неблагоприятная ситуация).

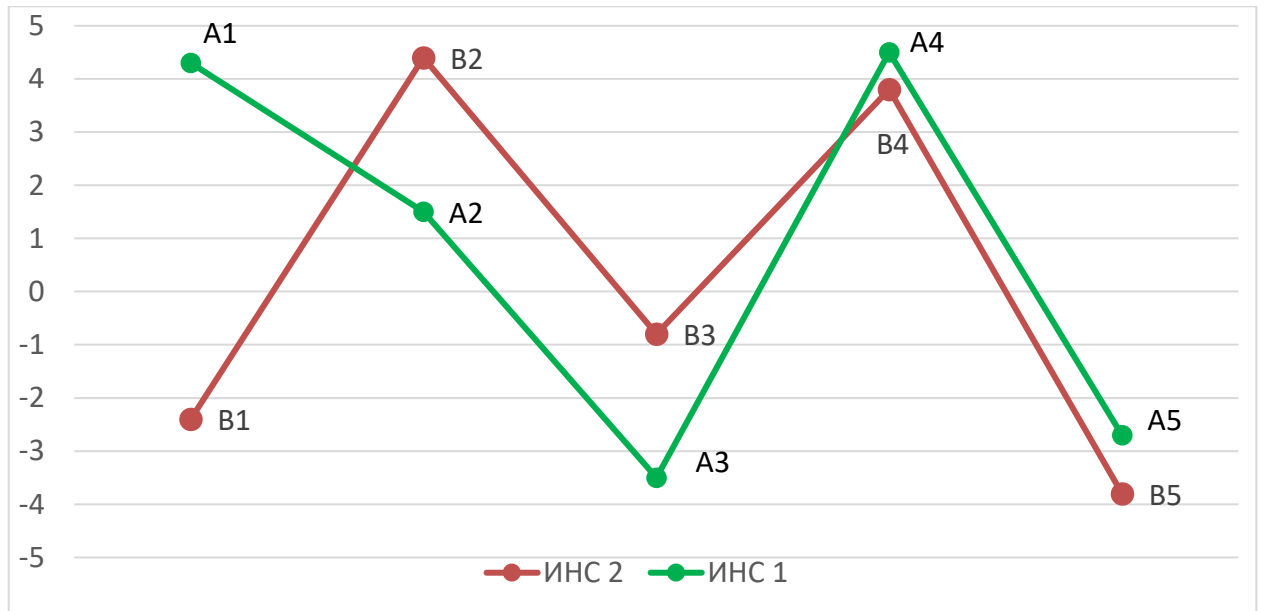


Рис.3.6. Возможные варианты взаимного положения погрешностей прогнозирования двух нейронных сетей

Максимальная взаимная компенсация ошибок прогнозирования при объединении нейронных сетей происходит в тех случаях, когда в выходных сигналах на первом уровне нейронных сетей преобладают два вида ситуаций: наиболее благоприятные (ошибки имеют разные знаки) и промежуточные (ошибки имеют одинаковые знаки, но разные по величине).

Неподходящими для объединения являются нейронные сети, у которых графики прогнозов близки, т.е. имеет место большое количество неблагоприятных ситуаций. Рассмотренные ситуации определяются по модулю разности ошибок прогнозирования на всей выборке:

$$\delta_{ijk} = |\varepsilon_{ik} - \varepsilon_{jk}|, \quad (3.8)$$

где ε_{ik} и ε_{jk} — ошибки прогнозирования:

$$\varepsilon_{ik} = P_{ikп} - P_{kф}, \quad \varepsilon_{jk} = P_{jkп} - P_{kф}; \quad (3.9)$$

i - тая и j - тая сравниваемые попарно нейронные сети (первая со второй, вторая с третьей и т.д.); k - тый прогнозный момент (k - тая реализация);

P_{ikn} и $P_{k\phi}$ – прогнозируемое и фактическое потребление электроэнергии в k -тый момент.

Парные сравнения нейронных сетей по совместимости для АИНС определяются из очевидного соотношения:

$$\delta_{ijk} - \delta_{jqk} = \delta_{iqk}$$

Подставляя выражения (3.9) в (3.8) в процентном выражении получим:

$$\delta_{ijk} \% = \left| \frac{P_{ikn} - P_{k\phi}}{P_{k\phi}} - \frac{P_{jqn} - P_{k\phi}}{P_{k\phi}} \right| 100\% = \frac{|P_{ikn} - P_{jqn}|}{P_{k\phi}} 100\%. \quad (3.10)$$

Ситуация будет неблагоприятной, т.е. графики прогнозов будут совпадать, а значит и будут совпадать и ошибки прогнозирования, если:

$$\delta_{ijk} \% \leq \Delta_p \%, \quad (3.11)$$

где $\Delta_p \%$ – пороговое значение, при равенстве которому или меньше разностью ошибок пренебрегают, и они приравниваются нулю.

Исследования показывают, что пороговую величину $\Delta_p \%$ необходимо устанавливать на уровне 1%.

Очевидно, чем меньше число разностей погрешностей $\delta_{ijk} \%$ не превышающих пороговое значение, тем меньше корреляция графиков погрешностей и, следовательно, больший эффект даст объединение сравниваемых нейросетей. Для количественной оценки этого показателя служит средняя сумма модулей разностей ошибок прогнозирования:

$$J_p = \frac{1}{N} \sum_{k=1}^N \delta_{ijk}, \quad (3.12)$$

где N – объем выборки (примеров обучения нейронной сети).

Отсюда следует, что из сравниваемых нейронных сетей та пара даст наибольший эффект от объединения в ансамбль, у которой величина критерия J_p максимальна.

Другим критерием является определение числа наиболее благоприятных ситуаций, когда ошибки прогнозирования в один и тот же момент имеют разные знаки и при объединении сетей скомпенсируют друг друга. Для определения таких

ситуаций необходимо рассчитать модуль суммы ошибок для каждого момента прогноза:

$$\mu_{ijk} = |\varepsilon_{ik} + \varepsilon_{jk}|. \quad (3.13)$$

Или в процентном выражении:

$$\mu_{ijk}\% = \left| \frac{P_{ikп} - P_{kф}}{P_{kф}} + \frac{P_{jkп} - P_{kф}}{P_{kф}} \right| 100\% = \frac{|P_{ikп} + P_{jkп} - 2P_{kф}|}{P_{kф}} 100\%$$

Как и в предыдущем случае, суммарная ошибка двух сравниваемых сетей принимается равной нулю, если

$$\mu_{ijk}\% \leq \Delta_p\%. \quad (3.14)$$

Пороговая величина $\Delta_p\%$ также берется равной 1%.

Наибольший эффект от объединения сетей будет при максимальном, в пределе равном всему объему выборки N , числе нулевых значений μ_{ijk} .

По аналогии с предыдущим случаем для количественной оценки этого критерия берется среднее значение суммы модулей, нескомпенсированных ошибок прогнозирования двух сравниваемых сетей:

$$J_c = \frac{1}{N} \sum_{k=1}^N \mu_{ijk}\%. \quad (3.15)$$

Анализ графиков погрешностей аппроксимации или прогнозирования, показывает, что по парный выбор нейронных сетей для ансамбля должен осуществляться по следующему алгоритму:

1. Выбирается пара по максимуму критерия J_p ;
2. В случае, когда у двух сравниваемых пар критерии J_p отличаются не более чем на 20%, выбор осуществляется по критерию J_c : выбирается та пара, у которой критерий J_c меньше.

Первый критерий характеризует степень отсутствия корреляции, второй – степень взаимной компенсации ошибок

3.4. Методика формирования ансамблей на основе взаимной компенсации погрешностей прогнозирования

Повышение точности и универсальности прогнозирования за счет применения ансамбля искусственных нейронных сетей (АИНС) наиболее доказательно реализуется на примерах систем краткосрочного прогнозирования потребления электроэнергии. Простейшим является двухуровневый АИНС с использованием мета алгоритма в качестве объединяющей (суммирующей) линейной ИНС (см. Рис. 3.5).

При синтезе данного ансамбля основной проблемой является определение количества нейронных сетей на первом уровне. Экспериментально количественный состав первого уровня АИНС определялся поэтапным увеличением количества нейронных сетей начиная с двух, используя для этого наиболее эффективные ИНС из Табл. 2.6. Результаты представлены в Табл. 3.2.

Табл. 3.2 Погрешности прогнозирования двухуровневого АИНС

Состав и количество нейронных сетей	Количество ИНС	Плотность распределения погрешностей прогнозирования (количество и проценты)				СО СКО
		0-3%	3-5%	5-10%	>10%	
ДИНС с ПР и ЛФА ИНС Элмана	2	601	84	34	1	1,82
		83.5%	11.7%	4.7%	0.1%	2,33
ДИНС с ПР и ЛФА ИНС Элмана ИНС с ПР и ЗВ	3	596	92	32	0	1,81
		82.8%	12.8%	4.4%	0%	2,31
ДИНС с ПР и ЛФА Нейросеть Элмана ИНС с ПР и ЗВ Линейная ИНС	4	594	91	35	0	1,83
		82.5%	12.6%	4.9%	0%	2,33
ДИНС с ПР и ЛФА ИНС Элмана ИНС с ПР и ЗВ Линейная ИНС ДИНС с ПР и ЗВ	5	57	108	37	2	1,89
		79.6%	15%	5.1%	0.3%	2,47
ДИНС с ПР и ЛФА ИНС Элмана ИНС с ПР и ЗВ Линейная ИНС ДИНС с ПР и ЗВ ИНГС с КР	6	564	120	34	2	1,91
		78.3%	16.7%	4.7%	0.3%	2,49

Представленные результаты получены при выборе типов нейронных сетей из наиболее эффективных для первого уровня АИНС методом сопоставления усредненных и точечных показателей погрешностей или ошибок прогнозирования.

Из Табл. 3.2 следует, что число нейросетей, выбираемых из 12 наиболее эффективных, увеличивать более пяти не имеет смысла, так как прогнозы добавляемых нейронных сетей имеют высокий коэффициент корреляции с прогнозами уже используемых сетей.

На основе этих показателей для базового уровня ансамбля выбраны из Табл. 2.6 следующие нейронные сети:

- искусственная нейронная сеть Элмана – ИНС Элмана ($CO=1,85$, $СКО=2,43$);
- искусственная нейронная сеть с прямым распределением и задержкой по времени – ИНС с ПР и ЗВ ($CO=1,89$, $СКО=2,36$);
- искусственная нейронная сеть с прямым распределением – ИНС с ПР ($CO=1,87$, $СКО=2,41$);
- двухслойная искусственная нейросеть с прямым распределением – ДИНС с ПР ($CO=1,74$, $СКО=2,27$ и $CO=1,80$, $СКО=2,36$);
- двухслойная искусственная нейросеть с прямым распределением и линейной функцией активации – ДИНС с ПР и ЛФА ($CO=1,87$, $СКО=2,41$).

Далее необходимо методом попарного сравнения этих ИНС по критериям J_p и J_c подобрать наилучшее их сочетание.

Самостоятельной задачей является определение типа объединяющей или суммирующей нейронной сети второго уровня. Проведенные исследования показали, что, когда требуется улучшить прогнозирование для стабильного графика электропотребления, необходимо использовать линейную ИНС, которая обеспечивает взвешенное суммирование результатов прогнозов, осуществляемых нейронными сетями предшествующего уровня ансамбля.

При значительно меняющихся графиках нагрузки необходимо использовать двухслойную ИНС с прямым распространением и задержкой по времени (ДИНС ПР и ЗВ), которая осуществляет более детально расчет коэффициентов значимости

отдельных прогнозов, либо двухслойную ИНС Элмана (ДИНС Элмана), которая также имеет лучшие аппроксимирующие свойства для сложных функциональных зависимостей. Результаты представлены в Табл. 3.3.

Табл. 3.3. Погрешности и ошибки прогнозирования двухуровневого АИНС

Ансамбль нейронных сетей	Кол-во нейронов	Плотность распределения погрешностей прогнозирования (количество и проценты)				СО СКО
		0-3%	3-5%	5-10%	>10%	
Ансамбль № 1						
<u>Первый уровень</u> 1. ДИНС с ПР и ЛФА 2. ИНС Элмана 3. ИНС с ПР и ЗВ 4. ДИНС с ПР	40-35 75 75 40-35					
<u>Второй уровень</u> ДИНС с ПР и ЗВ:	10-10	612 85%	84 11.7%	24 3.3%	0 0%	1,69 2,16
Ансамбль № 2						
<u>Первый уровень</u> 1. ДИНС с ПР и ЛФА 2. ИНС Элмана 3. ИСН с ПР и ЗВ 4. ДИНС с ПР	40-35 75 75 40-35					
<u>Второй уровень</u> ДИНС Элмана	10-10	613 85,1%	83 11.6%	24 3.3%	0 0%	1,70 2,18

Минимальный по структуре двухуровневый ансамбль состоит из трех нейросетей (Рис. 3.7): на первом уровне две различные и подобранные по критериям J_p и J_c нейросети и на втором уровне линейная нейросеть. Такой минимальный ансамбль можно использовать в качестве подсистемы или модуля для синтеза минимального трехуровневого ансамбля.

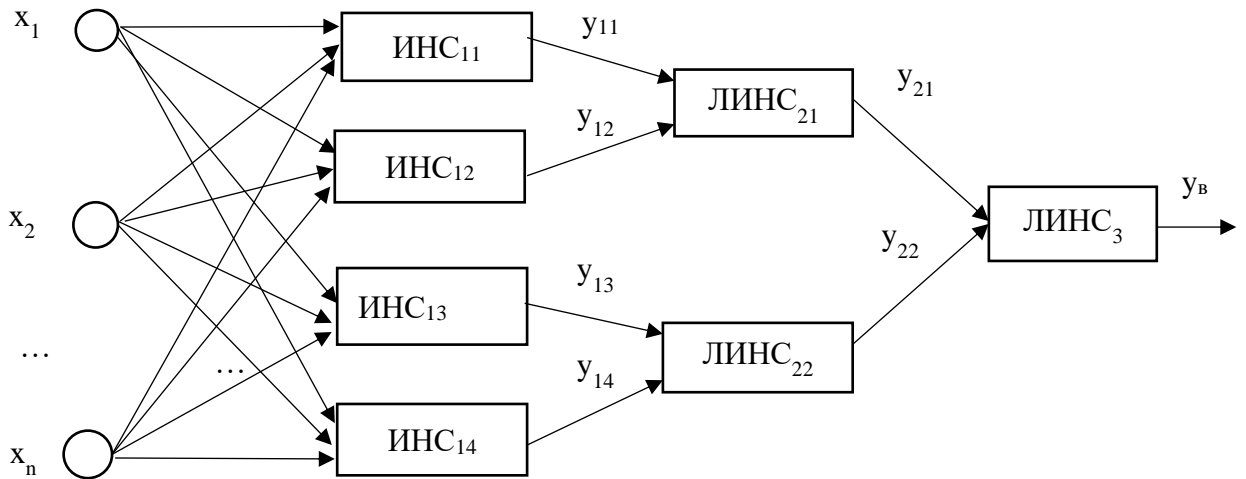


Рис.3.7. Трехуровневый ансамбль с минимальным числом нейронных сетей

Расчет критерия J_p для попарных сравнений нейронных сетей дает следующие результаты:

1. Трехслойная нейронная сеть Элмана с 75 нейронами в скрытом слое и нейронная сеть с прямым распределением и задержкой по времени с 75 нейронами в скрытом слое $J_p = 24\%$
2. Четырехслойная нейронная сеть Элмана и трехслойная нейронная сеть с прямым распределением и задержкой по времени с 75 нейронами в скрытом слое: $J_p = 12,2\%$.
3. Двухслойная нейросеть с прямым распределением и задержкой по времени и Двухслойная нейронная сеть Элмана: $J_p = 7,98\%$.

Максимальную величину критерия J_p (24%) имеет первая пара объединяемых ИНС. Следовательно, эта пара будет оптимальной по этому критерию для использования в ансамбле.

Расчет критерия J_c для попарных сравнений этих же ИНС дает следующие результаты:

- для первой пары ИНС критерий $J_c = 4,23\%$;
- для второй пары ИНС критерий $J_c = 4,54\%$;
- для третьей пары ИНС критерий $J_c = 4,69\%$.

Минимальную величину критерия J_c (4,23%) имеет также первая пара объединяемых ИНС. Следовательно, эта пара нейронных сетей по обоим

критериям J_p и J_c будет оптимальной для использования в ансамбле. Аналогично определяются остальные оптимальные парные объединения.

Результаты исследования вариантов построения ансамблей на основе использования линейных ИНС на втором и третьем уровнях, представлены в Таблице 3.4.

Табл.3.4. Ошибки и погрешности трехуровневых ансамблей

Ансамбль нейронных сетей	Кол-во нейронов	Плотность распределения погрешностей прогнозирования (количество и проценты)				СО СКО
		0-3%	3-5%	5-10%	>10%	
Трехуровневый ансамбль № 1						
1.1. ДИНС с ПР и ЛФА 1.2. ИНС Элмана	40-35 75	601 83.5%	84 11.7%	34 4.7%	1 0.1%	1,82 2,33
1.3. ИНС с ПР и ЗВ 1.4. ДИНС с ПР	75 40-35	604 83.9%	91 12.6%	25 3.5%	0 0 %	1,71 2,18
Результирующий прогноз	1	615 85.4%	86 12%	19 2.6%	0 0 %	1,68 2,12
Трехуровневый ансамбль № 2						
1.1. ДИНС с ПР и ЛФА 1.2. ИНС с ПР и ЗВ	40-35 75	586 81.4%	113 15.7%	21 2.9%	0 0 %	1,84 2,26
1.3. ИНС Элмана 1.4. ДИНС с ПР	75 40-35	605 83.7%	88 11.7%	27 3.6%	0 0 %	1,70 2,18
Результирующий прогноз	1	612 85%	83 11.5%	25 3.5%	0 0%	1,68 2,15
Трехуровневый ансамбль № 3						
1.1. ДИНС с ПР и ЛФА 1.2. ДИНС с ПР	40-35 40-35	610 84.7%	82 11.4%	28 3.9%	0 0%	1,71 2,19
1.3. ИНС Элмана 1.4. ИНС с ПР и ЗВ	75 75	592 82.2%	93 12.9%	35 4.9%	0 0%	1,82 2,35
Результирующий прогноз	1	616 85.6%	82 11.4%	22 3%	0 0%	1,67 2,12

В этой таблице приведены погрешности прогнозов, выдаваемые суммирующими ЛИНС второго уровня ансамбля (метаданные второго уровня

АИНС) и погрешности результирующего прогноза, выдаваемого ЛИНС третьего уровня. Данные Табл.3.4 наглядно демонстрируют эффект компенсации погрешностей прогнозирования по мере перехода с одного уровня ансамбля на другой. При этом уменьшение погрешности прогнозирования электропотребления по мере увеличения количества уровней в АИНС постепенно приближается к теоретическому пределу.

Увеличение числа уровней иерархии до четырех не дает какого-либо эффекта. Это обусловлено тем, что при переходе с одного уровня ансамбля на другой увеличивается корреляция между метаданными.

Для построения ансамбля среднесрочного прогнозирования электропотребления на месяц вперед проведена оценка эффективности различных видов нейронных сетей. Результаты представлены в Табл.3.5.

Табл.3.5. Оценка эффективности прогнозирования нейросетей на месяц вперед

Тип ИНС		ИНС с ПР		ДИНС с ПР		ИНС Элмана		ИНС с ПР и ЗВ	
Количество нейронов		25		15-10		25		25	
Месяц	Факт кВт/ч	Прогноз, Вт/ч	СО, (%)	Прогноз, кВт/ч	СО, (%)	Прогноз, кВт/ч	СО, (%)	Прогноз, кВт/ч	СО, (%)
Январь	278413	264583	4,97	262964	5,55	199293	0,47	269995	3,02
Февраль	241330	239683	0,68	232470	3,67	205689	3,10	240070	0,52
Март	247106	243579	1,43	243421	1,49	232267	0,57	245918	0,48
Апрель	218538	225095	3,00	219166	0,29	239727	2,14	221926	1,55
Май	206953	201368	2,66	199282	3,71	204067	2,92	199681	3,51
Июнь	183034	189233	3,39	190485	4,07	262125	3,30	191145	4,43
Июль	190734	192608	0,98	193606	1,51	239747	0,57	193854	1,64
Август	200242	196702	1,77	200935	0,35	240759	0,56	1972767	1,48
Сентябрь	199497	206039	3,28	212149	6,34	219785	1,35	205637	3,08
Октябрь	230961	239400	3,65	241376	4,51	199201	1,03	231000	0,02
Ноябрь	244962	243634	0,54	238009	2,84	188511	2,99	234135	4,42
Декабрь	261107	272362	4,31	262725	0,62	193616	1,51	263285	0,83
СО (%)			2,55		2,84		1,97		2,08

В результате анализа были отобраны следующие нейронные сети: ИНС с прямым распределением; двухслойная; ДИНС с прямым распределением; ИНС Элмана; ИНС с прямым распределением и задержкой по времени.

На следующем этапе проведено определение критериев J_p и J_c при попарном сравнении нейронных сетей:

1. ИНС с ПР и ДИНС с ПР $J_p = 12,58\%$; $J_c = 0,57\%$;
2. ДИНС с ПР и ИНС Элмана: $J_p = 20\%$; $J_c = 0,19\%$;
3. ИНС Элмана и ИНС с ПР и ЗВ: $J_p = 14,16\%$; $J_c = 0,39\%$;
4. ИНС с ПР и ЗВ и ИНС с ПР: $J_p = 18,49\%$; $J_c = 0,38\%$;
5. ИНС с ПР и ИНС Элмана: $J_p = 19,6\%$; $J_c = 0,3\%$;
6. ИНС с ПР и ЗВ и ДИНС с ПР: $J_p = 20\%$; $J_c = 0,12\%$.

Из этого следует, что оптимальной парой для объединения в ансамбль по критериям $J_p = \max$ и $J_c = \min$ являются нейронные сети ИНС с ПР и ЗВ и ДИНС с ПР. Результаты прогнозирования АИНС, состоящего из этих сетей на первом уровне и линейной ИНС на втором представлены в Табл. 3.6.

Табл.3.6. Среднесрочный прогноз на месяц вперед с помощью АИНС

Месяц	Реальное потребление, кВт.час	Прогнозное потребление, кВт.час	СО (%)
Январь	278413	274500	1,41
Февраль	241330	244055	2,13
Март	247106	245589	0,61
Апрель	218538	224090	1,54
Май	206953	197624	1,95
Июнь	183034	190081	1,85
Июль	190734	191958	0,64
Август	200242	197897	1,17
Сентябрь	199497	207501	2,01
Октябрь	230961	227286	1,59
Ноябрь	244962	242439	2,03
Декабрь	261107	264552	1,32
			СО = 1,52

Сравнение результатов Табл.3.5 и Табл.3.6 показывает, что применение двухуровневого ансамбля приводит к существенному уменьшению погрешностей прогнозирования.

Применение ансамбля ИНС для долгосрочных прогнозов (на год и более) не целесообразно, так как например, ИНС прямого распространения с задержкой по времени дает прогноз с СО < 1%. При возможной перспективе существенных изменений в объемах потребления электроэнергии из-за изменения числа

потребителей и режимов их работы необходимо применять сценарные методы, т.к. в этом случае прогнозирование на основе ретроспективной аппроксимации, в принципе, не эффективно.

В результате для синтеза нейросетевых систем прогнозирования определены варианты различной степени сложности и точности:

- *на основе одиночных нейронных сетей*: для краткосрочных прогнозов Табл.2.8, для среднесрочных прогнозов на неделю Табл.2.9, для среднесрочных прогнозов на месяц Табл.3.6 и для долгосрочных прогнозов Табл.2.10 и Табл.2.11;
- *на основе двухуровневых ансамблей*: для краткосрочных прогнозов Табл.3.2 и Табл.3.3; для среднесрочного прогнозирования на месяц Табл.3.6,
- *на основе трехуровневых ансамблей*: для краткосрочных прогнозов Табл.3.4.

У систем прогнозирования, построенных на основе одиночных нейронных сетей, погрешности СО и СКО находятся в среднем в диапазоне 2-4%. Применение ансамблей приводит к уменьшению погрешностей на 20-80 %. Это является существенным улучшением качества прогнозирования. Когда речь идет о потреблении электроэнергии в объемах сотен тысяч кВт часов, то идет борьба за каждую сотую долю процента. Другим преимуществом ансамблей является их универсальность по отношению к различным графикам и условиям электропотребления. При этом усложнение системы прогнозирования не приводит к каким-либо дополнительным издержкам.

3.5. Разработка алгоритма процессов отбора нейронных сетей и формирования ансамблей

Отбор нейронных сетей по условиям минимизации погрешностей прогнозирования и формирование из них ансамблей осуществляются путем проведения многоэтапных итерационных процессов, что вызывает необходимость автоматизировать данные процессы.

На Рис.3.8 представлена укрупненная блок-схема системы автоматизации процесса формирования АИНС для прогнозирования электропотребления.



Рис.3.8. Укрупненная блок-схема процесса формирования ансамблей

В базе данных содержатся различные типы искусственных нейронных сетей и полученные результаты краткосрочных, среднесрочных и долгосрочных прогнозов.

Массив данных состоит из следующего множества показателей:

$$R = \langle V_i, W_i, T_k, P_{k\Phi}, P_{ikn}, \varepsilon_{ik}, \varepsilon_{ico}, \varepsilon_{иско}, \eta_{\Delta i\%} \rangle \quad (3.16)$$

где: V_i – тип i - той нейронной сети;

W_i – структура i - той нейронной сети;

T_k – k - тый момент времени, для которого дается прогноз;

$k = T, D, M, Q$ – значение часа, дня, недели, месяца, года;

$P_{k\Phi}$ – фактическое потребление электроэнергии в k - тый момент;

P_{ikn} – прогнозируемое потребление электроэнергии, полученное с помощью i - той нейронной сети для k - того момента времени;

ε_{ik} – погрешность или ошибка прогнозирования i - той нейронной сети для k - того момента времени;

ε_{ico} – среднее отклонение i - той нейронной сети;

$\varepsilon_{иско}$ – среднеквадратичное отклонение прогноза i - той нейронной сети;

$\eta_{\Delta i\%}$ – процент прогнозов с погрешностями, находящимися в интервалах $\Delta_1 = 0-3\%$, $\Delta_2 > 3-5\%$, $\Delta_3 > 5-10\%$, $\Delta_4 > 10\%$.

Алгоритм подпрограммы выбора эффективных ИНС в соответствии с методикой, изложенной в разделе 3.3, представлен на Рис.3.9.

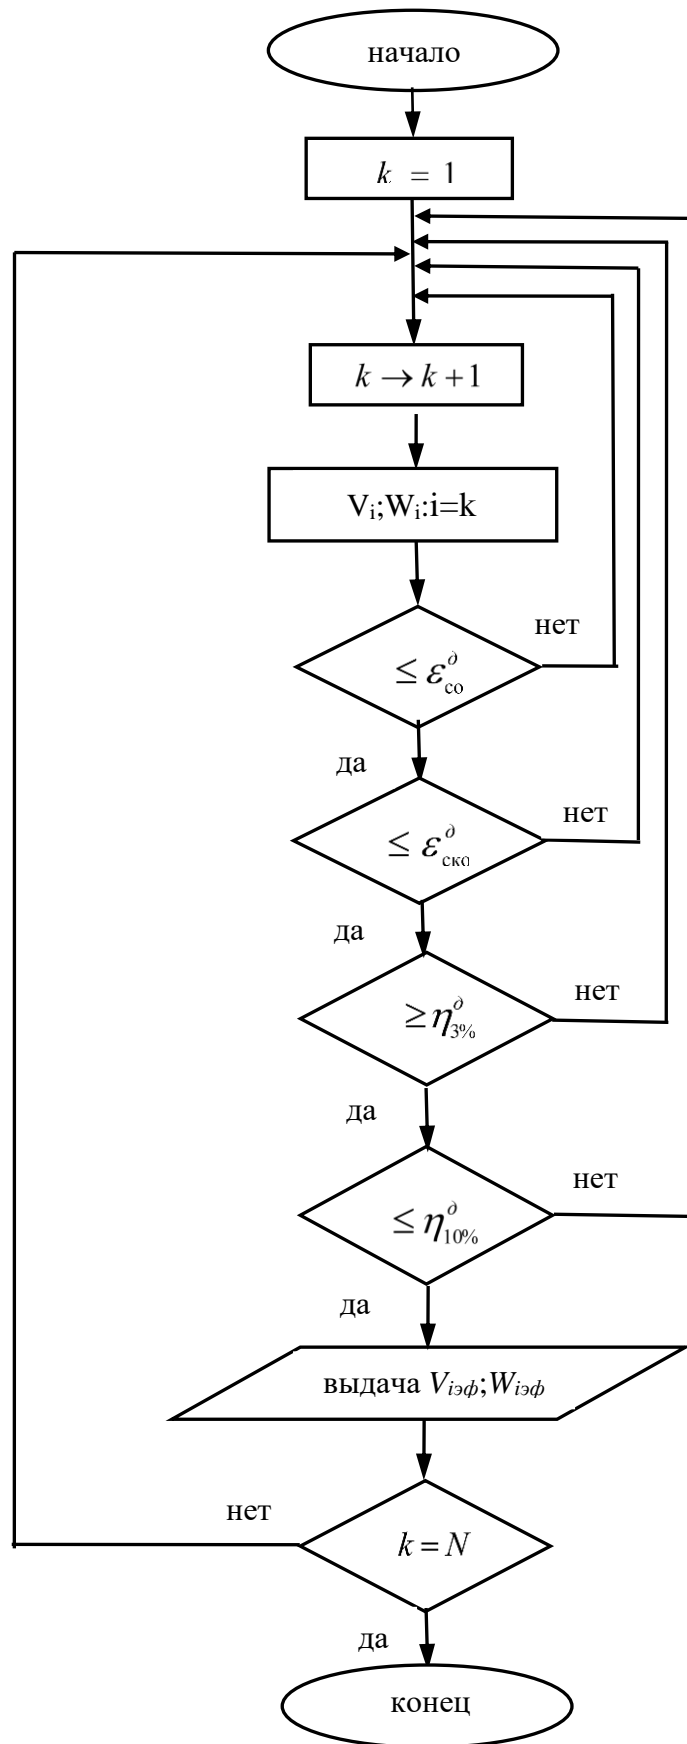


Рис.3.9. Выбор эффективных нейронных сетей: схема алгоритма

На Рис.3.9 приняты следующие обозначения:

$\varepsilon_{ico}^D, \varepsilon_{icko}^D, \eta_{3\%}^D, \eta_{10\%}^D$ – допустимые значения соответствующих показателей погрешностей прогнозирования;

- $V_{i\phi}$ и $W_{i\phi}$ – нейронная сеть эффективного типа и эффективной структуры;
- N – общее число нейронных сетей определенного типа и структуры, информация о прогнозных свойствах которых содержится в базе данных;
- $k \in N$ – порядковый номер нейронной сети.

В начале цикла из базы данных выбирается нейронная сеть V_i - типа и W_i - структуры. На следующем шаге определяется условие: меньше или нет среднее отклонение i -той нейронной сети допустимого значения, которое определено равным 2%.

Если «нет», из базы данных выбирается следующая нейронная сеть. Если «да», то определяется меньше или нет среднеквадратичное отклонение i -той нейронной сети допустимого значения, которое определено равным 2,5%. При удовлетворении этого условия производится проверка, находится ли плотность распределения погрешностей прогнозирования, определяемая количеством прогнозов с погрешностями, находящимися в интервалах $\Delta_1= 0-3\%$, $\Delta_2>3-5\%$, $\Delta_3>5-10\%$, $\Delta_4>10\%$. Как ранее определено, количество ошибок единичных прогнозов в интервале 0-3%, должно быть более 70%, а в интервале $\Delta_4>10\%$ должно быть менее 4%. Если нейронная сеть удовлетворяет этим условиям, она возвращается в подпрограмму формирования АИНС. Далее осуществляется переход в начало цикла.

Алгоритм подпрограммы формирования ансамбля из эффективных нейронных сетей в соответствии с методикой, изложенной в разделе 3.4, отличается более сложной структурой.

С целью отбора нейронных сетей, объединяемых в ансамбль, необходимо попарное сравнение по критерию несовпадения их графиков прогнозов $J_{pq} = f(W_{iq}, W_{jq})$, рассчитываемого по формуле (3.13).

Для расчета этого критерия в схеме алгоритма, представленного на Рис.3.10,

из результатов расчета формируется индексная Табл.3.7, обозначенная в схеме алгоритма через R . Индекс – порядковый номер сравниваемых пар нейронных сетей: $q = 1, 2, q_{\max}; q_{\max} = 0,5N(N-1)$.

Табл.3.7. Индексная таблица результатов расчета критериев J_{pij}

J_{pij}	Номера нейронных сетей	
q	i	$j(j \neq i)$
J_{p1}	i_1	j_1
\vdots	\vdots	\vdots
J_{pN}	i_N	j_N

В блоке $Sort(R, J_p)$ производится сортировка критериев по убыванию и определяется последовательность максимальных критериев J_{pm} .

Далее выделяются L этих критериев, где L – число пар нейронных сетей, необходимых для формирования ансамбля. Для использования в ансамбле выбирается та нейронная сеть, у которой критерий J_{pm} больше (правый переход на схеме алгоритма на Рис.3.10).

В случае, когда эти критерии примерно одинаковые по величине $J_{pm} \approx J_{pm+1}$, как установлено в разделе 3.4, с целью определения наиболее эффективной пары сетей дополнительно используется критерий эффективности взаимной компенсации ошибок прогнозирования J_c (левое ответвление на схеме алгоритма). Для этих пар рассчитываются с помощью выражения (3.16) величины критериев:

$$J_{cm} = f_c(W_{im}, W_{jm}); J_{cm+1} = f_c(W_{im+1}, W_{jm+1}).$$

В зависимости от того, у какой пары нейронных сетей значение критерия J_{cm} или критерия J_{cm+1} меньше, та и выбирается для формирования ансамбля.

Таким способом определяется весь набор нейронных сетей, из которых формируется ансамбль

3.6. Выводы по главе 3

1. Исследования показали, что не удастся синтезировать универсальную нейронную сеть, которая давала бы минимально достижимую погрешность на всём

периоде прогнозирования. Поэтому для создания системы прогнозирования предложено использовать ансамбли нейронных сетей.

2. Осуществлена классификация ансамблей нейронных сетей в зависимости от метода получения результирующего прогноза. Проведен анализ данных методов с позиции применимости их для прогнозирования электропотребления.

3. Сформулированы общие положения формирования ансамбля нейронных сетей. Определено, что для объединения нейронных сетей в ансамбль целесообразно использовать стэкинг, реализуемый в виде иерархической структуры, осуществляющей прогнозирование поэтапным итерационным методом. При этом необходимо решить ряд задач по методике обучения, выбору типов и определению количества нейронных сетей на каждом уровне иерархии.

4. Отличительной особенностью процесса обучения ансамбля является то, что сети первого уровня обучаются на основном подмножестве ретроспективных данных, а для сетей последующих уровней используется тестирующее подмножество. Такое применение разных выборок исключает явление переобучения.

5. Разработан двухэтапный метод формирования ансамбля прогнозирования электропотребления. В состав ансамбля на первом этапе выбираются отдельные нейронные сети по критерию точности на основе усредненных и точечных показателей погрешностей прогнозирования. ИНС должны иметь следующие величины погрешностей: $CO \leq 1,9\%$; $СКО \leq 2,5\%$; количество прогнозов, входящих в интервал $0-3\%$, должно быть $\geq 70\%$; а погрешностей прогнозирования, входящих в интервал $\Delta_4 > 10\%$ должно быть минимальным ($0-4\%$) на достаточно представительной выборке графика электропотребления.

6. На втором этапе объединяемые нейронные сети отбираются на основе попарного сравнения по двум критериям: по максимуму критерия, определяющего степень несовпадения или корреляции графиков погрешностей, и по критерию, определяющему степень взаимной компенсации ошибок.

7. Установлено, что для краткосрочного прогнозирования наибольшая точность достигается при использовании трехуровневого ансамбля, для среднесрочного – при использовании двухуровневого ансамбля, для долгосрочного – при использовании одиночной нейронной сети. Получена структура трехуровневого ансамбля с минимальным числом нейронных сетей.

8. Решена задача определения типов объединяющих нейронных сетей. При относительно стабильных графиках электропотребления необходимо использовать линейную нейронную сеть, при значительно меняющихся графиках нагрузки, когда требуется повысить адаптационные свойства системы прогнозирования, целесообразно использовать четырехслойные ИНС – с прямым распространением и задержкой по времени или сеть Элмана.

9. Для автоматизации процессов выбора эффективных нейронных сетей и формирования из них ансамблей по предлагаемой методике разработаны алгоритмы, реализуемые программным путем. Применение ансамблей приводит к уменьшению погрешностей на 20-80 %.

ГЛАВА 4. ПРАКТИЧЕСКАЯ РЕАЛИЗАЦИЯ СИСТЕМ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ

Применение прогнозирования является эффективным средством повышения качества управления. Однако процесс прогнозирования в автоматизированных системах управления технологическими процессами (АСУ ТП), особенно в такой сложной системе, как распределительные электрические сети, является более многофункциональным. АСУ ТП в свою очередь состоит из автоматизированной системы диспетчерского управления (АСДУ) и автоматизированной системы технологического управления (АСТУ) [95-100]. Прогнозирование в этих системах необходимо для решения всего спектра задач текущего планирования и оперативного управления режимами работы электрических подстанций и распределительных электросетей.

АСДУ и АСТУ строятся, как распределённая иерархическая система. Роль подсистем нижнего уровня играют системы сбора, обработки и передачи технологической информации о режимах и состоянии оборудования. На вышестоящих уровнях осуществляется поддержка управления функционирования сетей и обеспечивается автоматизация основных функций оперативно-технологической и производственно-технической деятельности служб на основе технологической информации [101-104].

Как уже указывалось, для повышения эффективности выполнения практически всех функций диспетчерского и технологического управления необходимо использование не только ретроспективной и текущей информации об электропотреблении, но и прогнозные упреждающие данные, как на границах ответственности региональной сетевой компании, так и на отдельных ее участках. При этом очевидно, что чем более будут детализированы эти данные, тем появляется больше возможностей для качественного управления электроснабжением. При этом центральную и интегрирующую роль играет автоматизированная информационно-измерительная система коммерческого и технического учета электроэнергии (АИИС КУЭ и АИИС ТУЭ) [105-107].

Важное значение имеет также применение прогнозирования в автоматизированных организационно-экономических системах закупки, передачи и распределения электрической энергии [108].

Ниже рассмотрены более подробно применение систем прогнозирования для повышения эффективности функционирования сбытовых и электросетевых компаний.

4.1. Применение систем прогнозирования для управления экономической эффективностью закупки, передачи и распределения электрической энергии

После разделения на самостоятельные субъекты производителей электроэнергии, компаниям по ее транспортировке, распределению и сбыту потребовалась специальная организация рынка электроэнергии и мощности. Наиболее важными особенностями рынка электрической энергии являются:

1. электроэнергия является в высшей степени стандартизированным продуктом, поставляемым множеством производителей в общие электрические сети и мгновенно потребляемым оттуда большим количеством потребителей;
2. спрос на рынке электроэнергии не всегда равен потреблению;
3. производители должны поставлять в общую сеть электрическую мощность в соответствии со своими обязательствами (или заданием), а все потребители должны потреблять электрическую мощность точно в соответствии со своими обязательствами.

С учетом этих особенностей созданы Федеральный оптовый и розничный рынки электроэнергии и мощности (ФОРЭМ) [109, 110].

Связь этих рынков с технологической системой производства и передачи электроэнергии представлена на Рис.4.1 На оптовом рынке электростанции продают электроэнергию оптовым покупателям, которые осуществляют оптовую покупку и розничную продажу электрической энергии.

На оптовом рынке осуществляют торговлю крупные поставщики и потребители электроэнергии, в том числе сбытовые компании через конкурентные механизмы торговли: долго- и среднесрочные двусторонние договоры, рынок на сутки вперед, балансирующий рынок.

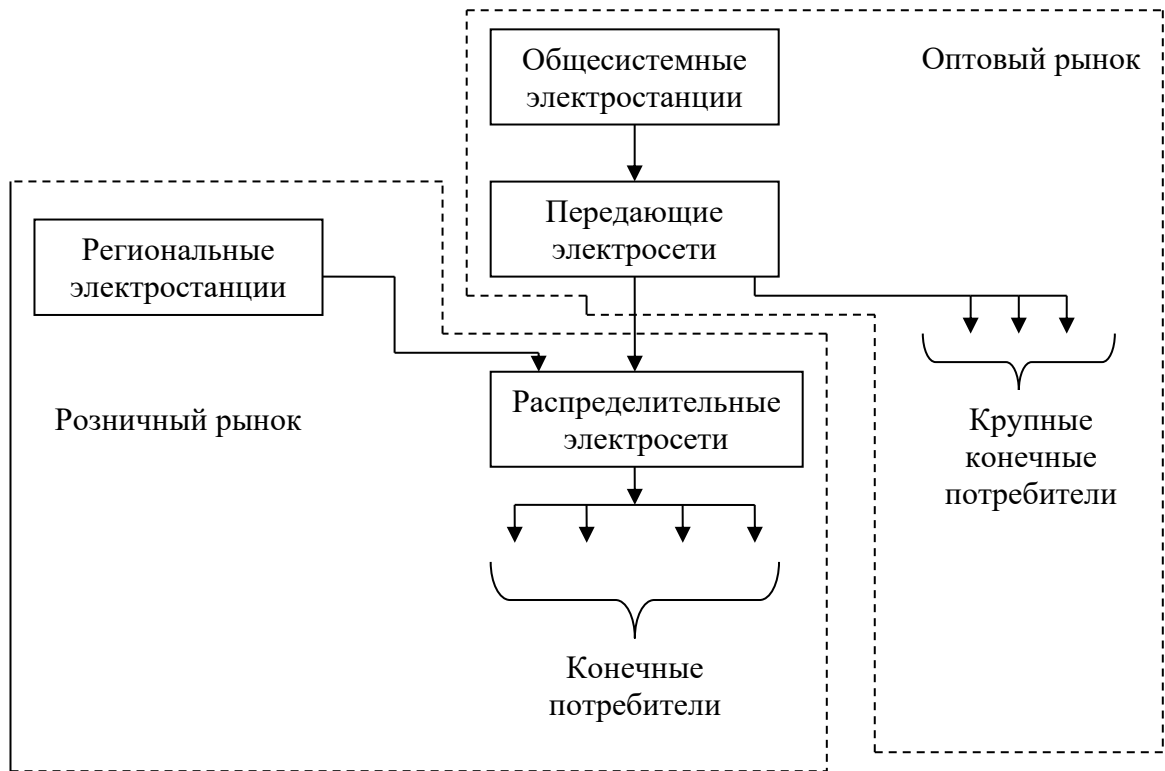


Рис.4.1. Взаимосвязь оптового и розничного рынков электроэнергии и мощности с технологической системой производства и передачи электроэнергии

На розничном рынке энергосбытовые компании продают электроэнергию по розничным ценам розничным конечным потребителям. Поставка электроэнергии осуществляется по распределительным сетям среднего и низкого напряжения. Основные объемы электроэнергии распределяются в рамках долгосрочных (на срок до 5 лет) договоров между поставщиками и потребителями. Рынок на сутки вперед позволяет участникам оптового рынка приобрести недостающую или продать излишнюю электроэнергию, корректируя, таким образом, изменения в потреблении и производстве электроэнергии, не учтенные в рамках долгосрочных договоров. Цена рынка на сутки вперед формируется на основании конкуренции заявок потребителей и поставщиков, проходящей в форме аукциона, на каждый час суток. Балансирующий рынок предназначен для торговли отклонениями и позволяет приводить в соответствие объемы производства и потребления электроэнергии в реальном времени. Цена балансирующего рынка формируется на основании конкурентного отбора заявок поставщиков. На рынке на сутки вперед и балансирующем рынке торговля ведется по свободным, не регулируемым

государством ценам [111-114]. Структура деятельности сбытовых компаний представлена на Рис.4.2.

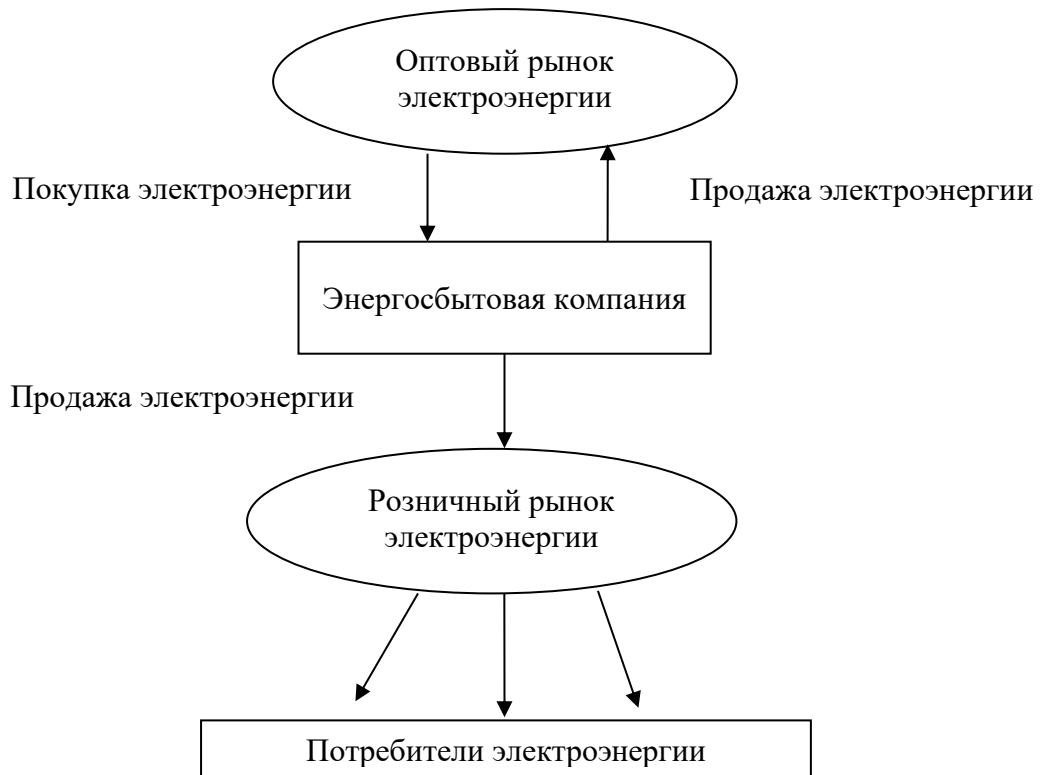


Рис.4.2. Структура деятельности энергосбытовой компании

На основе принципов ФОРЭМ, а также входящих в него субрынков: рынка «на сутки вперед», балансирующего рынка, разработан алгоритм работы системы поддержки принятия управленческих решений [115] для сбытовой компании на указанных рынках (Рис.4.3).

На первом этапе необходимо получить достоверный прогноз почасового потребления электроэнергии на сутки вперед с точностью 2-5%, который является основой принятия эффективного решения. На втором этапе проводится анализ графиков цен на электроэнергию на рынке «на сутки вперед» и балансирующем рынке, с целью определить знак и величину отклонения прогнозного значения потребления электрической энергии от фактического.

При противоположной ситуации, когда цена на рынке «на сутки вперед» выше цены на балансирующем рынке, должно приниматься решение о формировании заявки с положительным отклонением, с целью докупить недостаток электроэнергии на балансирующем рынке по более низкой цене.

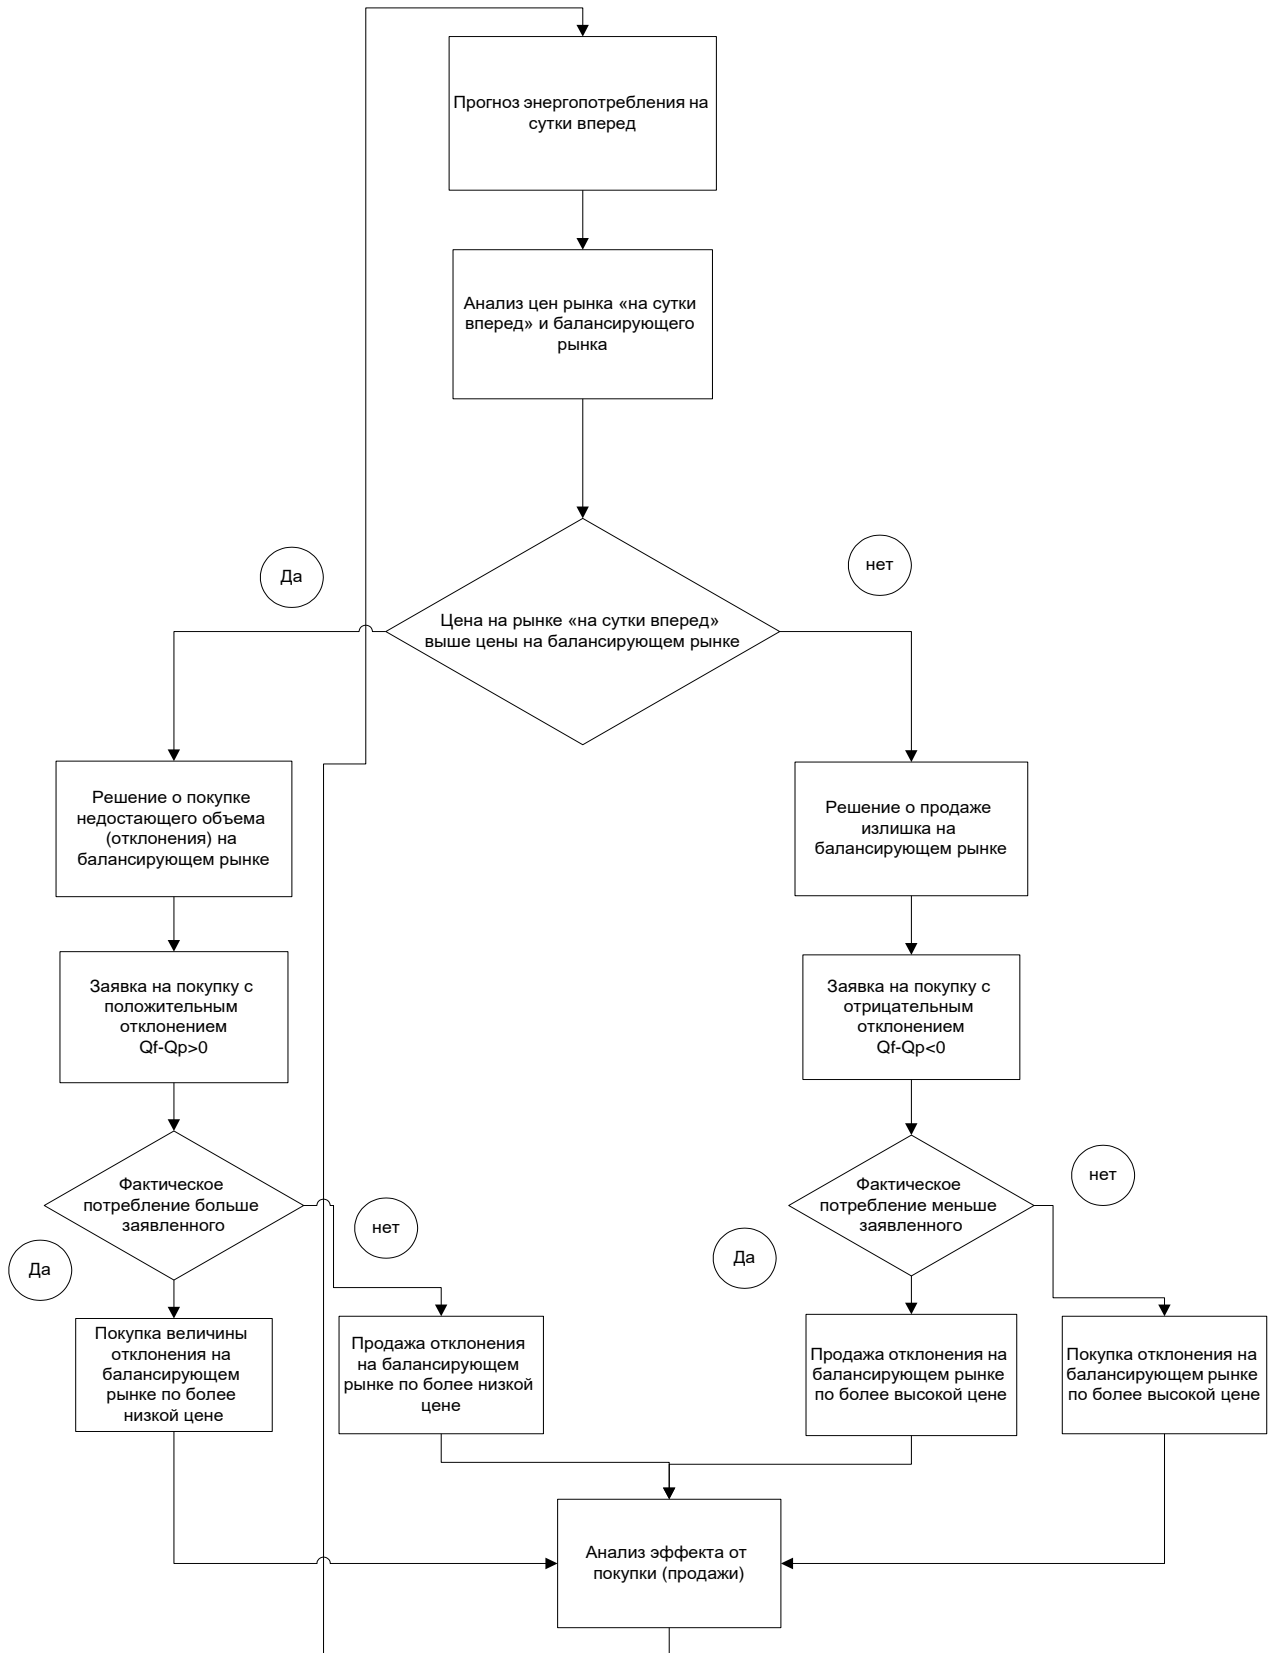


Рис.4.3. Системы поддержки принятия управленческих решений для сбытовой компании на рынке электроэнергии. Схема алгоритма

В ситуации, когда фактическое потребление больше заявленного получается положительный эффект от покупки недостающего объема по более низкой цене. В

противном случае эффект отрицательный, потому что необходимо продать излишний объем по цене ниже, чем он был куплен.

По окончании торгового дня проводится анализ эффекта от покупки и/или продажи для оценки эффективности принятых решений и формирования рекомендаций к следующей торговой сессии.

Обобщение целей и задач применения систем прогнозирования при управлении экономической эффективностью закупки, передачи и распределения электрической энергии дает три сферы их применения:

- краткосрочное прогнозирование необходимо энергосбытовым компаниям для осуществления экономически целесообразных операций по покупке и продаже электроэнергии на ФОРЭМ;

- среднесрочное прогнозирование необходимо электросетевым компаниям для расчетов и формирования тарифов, а также для оптимизации распределения нагрузки между производителями электроэнергии;

- долгосрочное прогнозирование необходимо для перспективного планирования и управления развитием энергетических компаний и отрасли в целом.

4.2. Схемы применения систем прогнозирования для диспетчерского управления электрическими сетями

Проведенный анализ структур АСУ электрических распределительных сетей, в которые входят непосредственно электрические сети и подстанции напряжением 6-110 кВт показывает, что основное направление развития систем управления происходит в направлении интеграции автоматизированных систем диспетчерского управления (АСДУ) и автоматизированных систем технологического управления (АСТУ), информационной основой которых являются АИИС КУЭ и ТУЭ [103-105]. Развитие автоматизированных систем управления электрическими распределительными сетями (АСУ ЭРС) происходит в направлении формирования иерархических систем, и их основой являются подсистемы коммерческого и технического учета [106-108].

Обобщенная структурная схема оперативного диспетчерского управления представлена на Рис.4.4, где обозначено: ЗЦК – заданные цели и критерии эффективного управления; ДУ – диспетчерское управление; РЭС – распределительные электрические сети; ПЭ – потребители электроэнергии; АСКУЭ и АСТУЭ – автоматизированные системы коммерческого и технического учета электроэнергии.

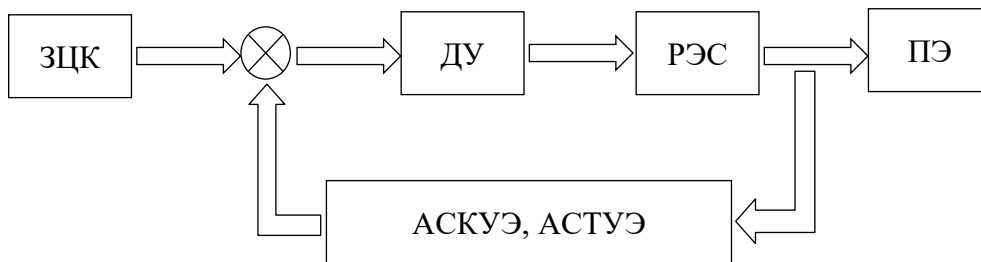


Рис.4.4. Замкнутая система оперативного управления

При плано-прогнозном управлении распределительными электрическими сетями, очевидно, необходима информация о потреблении электроэнергии на период упреждения. Поэтому схему такого управления необходимо дополнить, как представлено на Рис.4.5, контуром управления, в котором используется прогнозная информация.

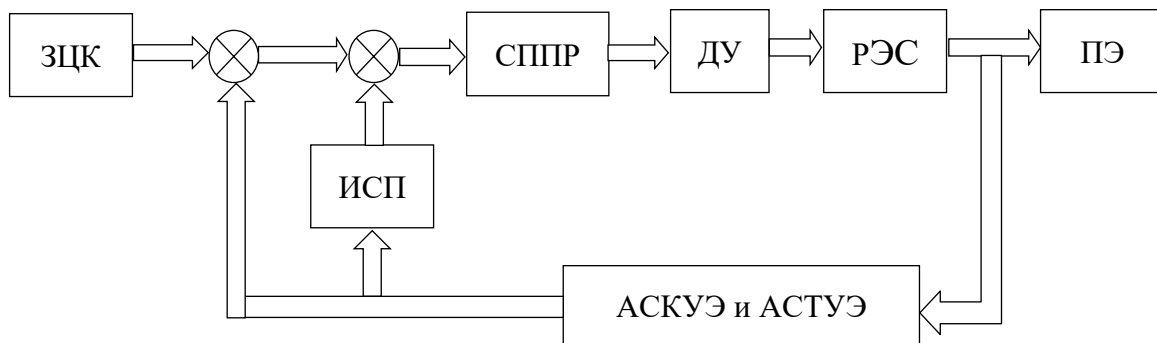


Рис.4.5. Структурная схема плано-упреждающего управления

На Рис.4.5 обозначено: ЗЦК – заданные цели и критерии эффективного управления; СППР – система поддержки принятия решений; ДУ – диспетчерское управление; РЭС – распределительные электрические сети; ПЭ – потребители электроэнергии; АСКУЭ и АСТУЭ – автоматизированные системы коммерческого и технического учета электроэнергии; ИСП – система прогнозирования.

Структурная схема системы прогнозирования, построенная на основе ансамбля искусственных нейронных сетей, представлена Рис.4.6.

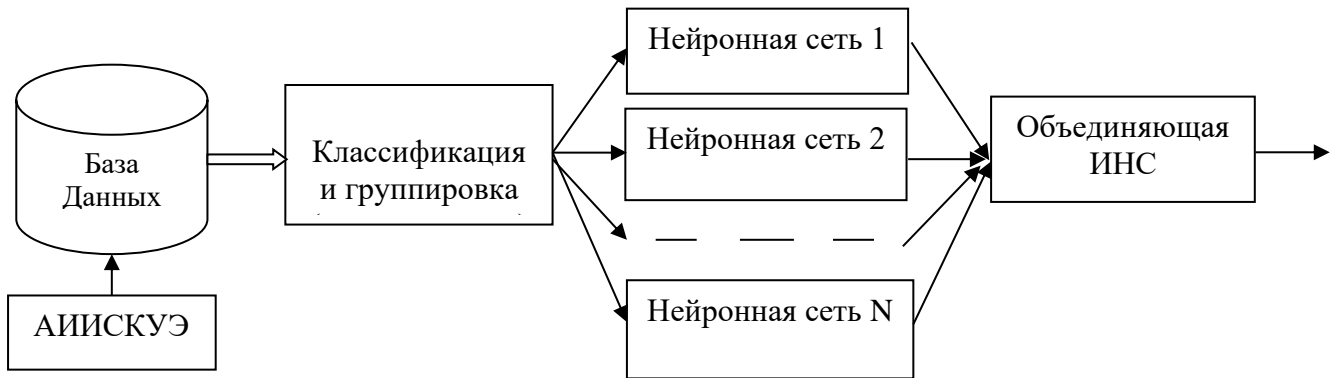


Рис.4.6. Схема системы прогнозирования на основе ансамбля нейронных сетей

В соответствии с рассмотренными в третьей главе функциональными схемами, в общем случае она содержит базу данных электропотребления (БД), нейронную сеть, классифицирующую вид графиков нагрузки, нейронные сети, осуществляющие прогнозирование, и нейронную сеть, обобщающую результаты прогнозирования предыдущих комитетов нейронных сетей.

В состав общей информационной системы должны входить специализированные информационные системы прогнозирования (Рис.4.7).

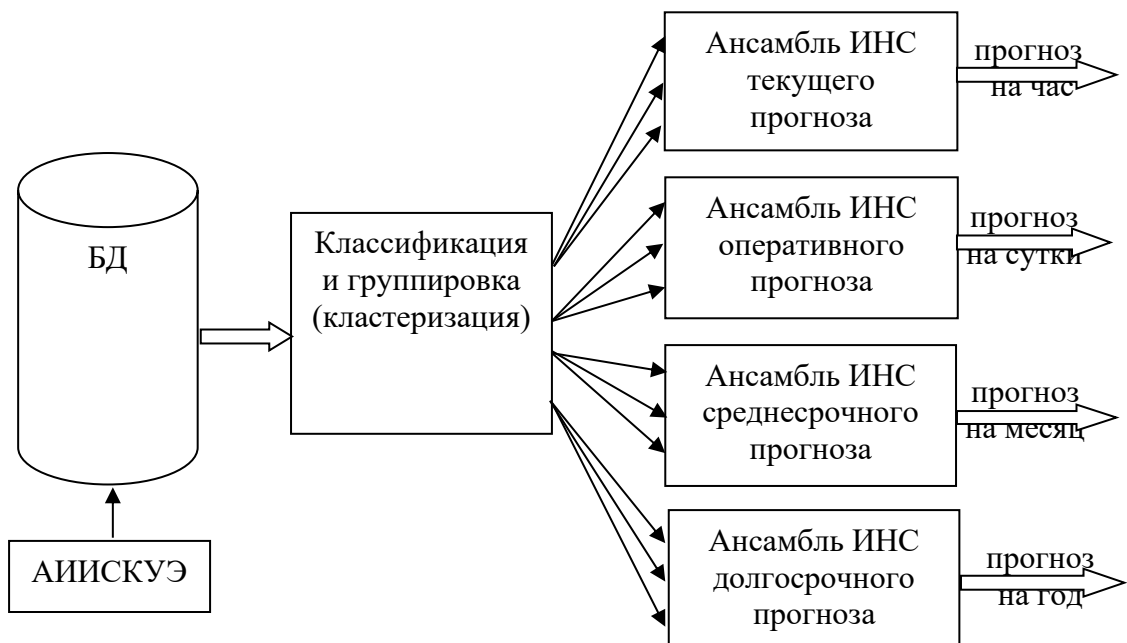


Рис.4.7. Структура общей интегрированной системы прогнозирования

В настоящее время принятие управляющих решений производится «вручную» операторами СДУ. Однако в перспективе для выработки альтернатив

управляющих решений СППР должна иметь базу знаний и системный решатель, которые целесообразно реализовать на основе нечеткого моделирования.

4.3. Практическая реализация системы прогнозирования в составе диспетчерского управления

Как сформулировано в задачах данного исследования, расширение функциональных возможностей АИИС КУЭ и АИИС ТУЭ, а, следовательно, и АСТУ и в целом АСУ электрических распределительных систем должно осуществляться с помощью применения подсистемы прогнозирования электропотребления на всех уровнях иерархической системы управления в виде систем поддержки принятия управленческих решений. На Рис.4.8 представлена структура взаимосвязей между иерархическими уровнями АИИС КУЭ и системой поддержки принятия управленческих решений на основе прогнозирования электропотребления.

На нижнем уровне первичного измерения электропотребления информационная система обеспечивает «интеллектуальную» фильтрацию и верификацию результатов измерения (заполнение пропущенных измерений, корректировка аномальных данных, получаемых по техническим или субъективным причинам и т.п.).

На уровне информационно-вычислительного комплекса системы управления распределительными электросетями, где производится сбор и обработка данных по отдельным энергообъектам, система прогнозирования осуществляет упреждающее выявление технических и коммерческих потерь с целью обеспечения энергосберегающего управления.

На уровне центра сбора данных по всему предприятию (сетевой компании) информационная система выдает прогнозную информацию на разные интервалы времени.

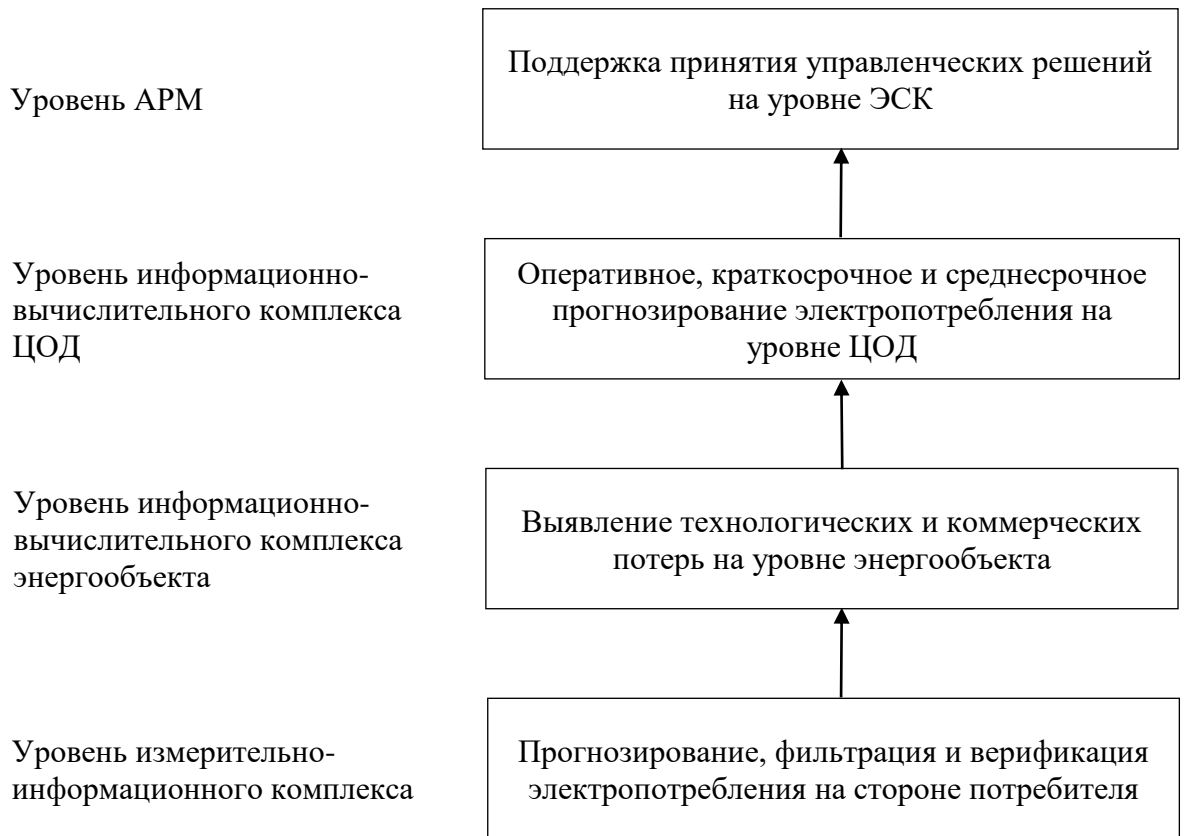


Рис.4.8. Иерархическая система поддержки принятия управленческих решений на основе прогнозирования электропотребления

На уровне автоматизированных рабочих мест (АРМ) управления электросетевой компанией (ЭСК) информационная система прогнозирования участвует в реализации функций поддержки принятия управленческих решений. Оперативный и диспетчерский персонал осуществляет контроль и управление электрическими сетями и подстанциями. Службы, занимающиеся планированием, осуществляют бизнес-аналитику и экономические расчеты тарифов.

В виду большого количества возможных решаемых задач информационную систему прогнозирования целесообразно реализовать несколькими способами.

Прямой способ заключается в использовании готовой среды проектирования. В данной среде создаётся модель, производится её обучение и дальнейшее использование. Однако ввиду высокой стоимости готовой среды проектирования для конечного пользователя такой способ становится не приемлемым. Например,

пакет Matlab, совместно с инструментарием Neural Network Toolbox обойдется конечному пользователю в 3000 евро [116]. Другой пакет, Neuro Solutions Pro, стоит \$1500 [117].

Второй способ заключается в использовании библиотек и фреймворков для различных языков программирования, позволяющих работать с нейронными сетями. Однако система, построенная на основе таких библиотек, может функционировать хуже, чем аналогичная система, построенная в готовой среде моделирования из-за использования упрощенных алгоритмов обучения. Более того, в случае использования ансамблей ИНС библиотеки нейронных сетей должны содержать все требуемые виды, входящие в ансамбль нейронных сетей, а также алгоритмы их обучения, тогда как в распространённых библиотеках имеется лишь ограниченное число наиболее популярных видов ИНС.

В связи с этим целесообразно использовать два вида схем организационного построения системы прогнозирования: «система прогнозирования как услуга» и «прогноз как услуга». Эти схемы взаимодействия позволяют упростить процедуру создания эффективного программного продукта и обеспечить его качественную эксплуатацию с минимальными издержками.

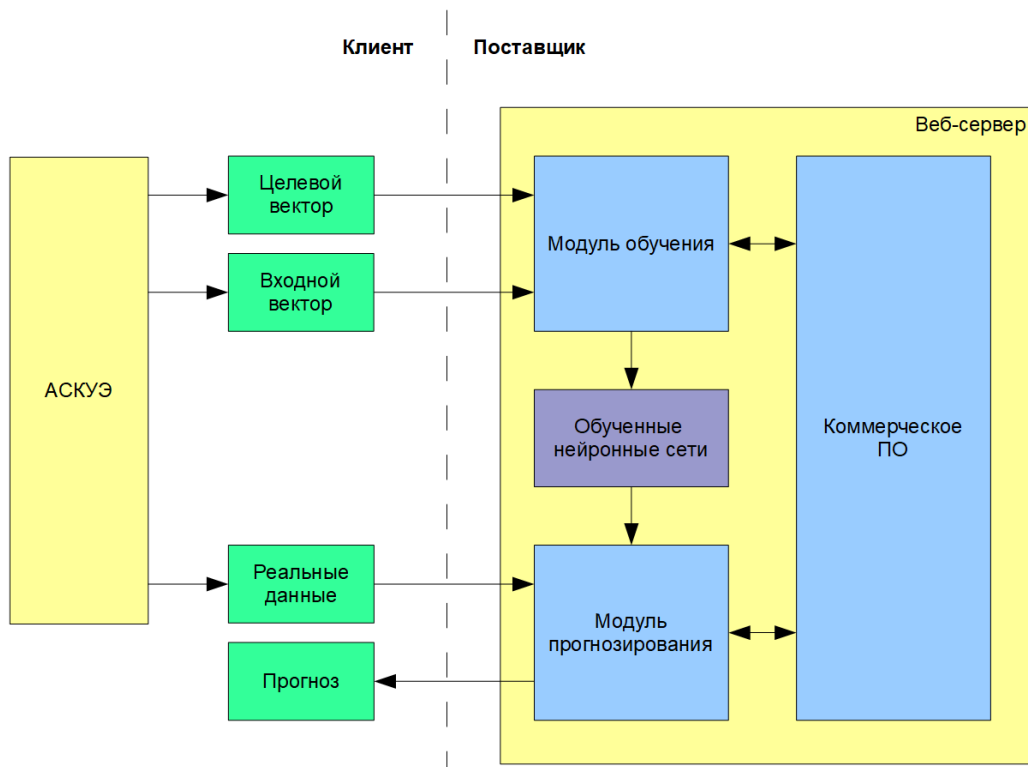


Рис.4.9. Взаимодействие по схеме «прогноз как услуга»

При схеме взаимодействия «прогноз как услуга» поставщик прогнозов получает от энергетической компании данные, необходимые для получения прогнозов, освобождая компанию от расходов на программное обеспечение (ПО) и на специалистов по его эксплуатации. Вторым преимуществом такой схемы является то, что поставщик, благодаря узкой специализации имеет возможность постоянно совершенствовать модели и методы прогнозирования и расширять рынок услуг, повышая рентабельность своего бизнеса. Недостатком является возможность потери оперативности.

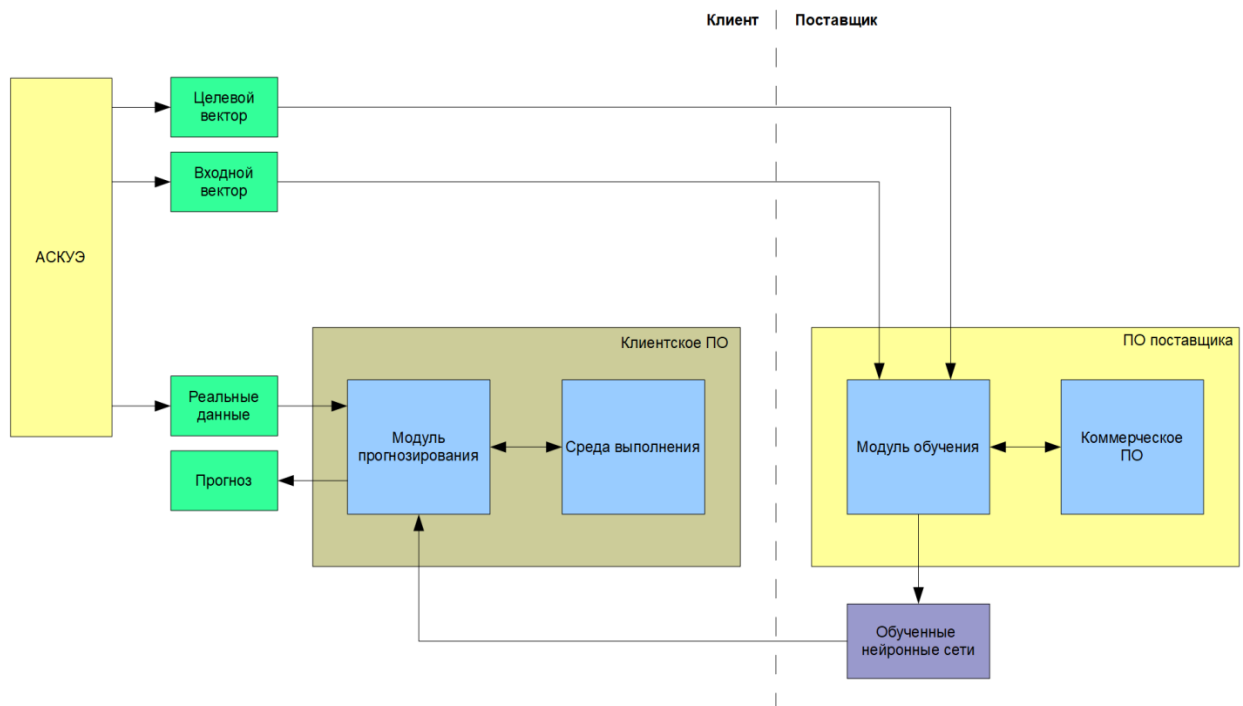


Рис.4.10. Взаимодействие по схеме «система прогнозирования как услуга»

При взаимодействии «система прогнозирования как услуга» прогнозирование осуществляется самой энергетической компанией, а актуализация (обучение) и модернизация системы производится поставщиком или разработчиком системы прогнозирования. Достоинством такой схемы является повышение оперативности, а недостатками – увеличение капитальных и текущих расходов и возможное отставание от прогресса в области прогнозирования.

4.4. Разработка программного обеспечения и практические результаты применения разработанных методов и средств

Большинство предлагаемых на рынке программных продуктов для прогнозирования может быть использовано только для решения узконаправленных задач с заданным набором специфических параметров информационной системы прогнозирования, под который данный программный продукт был разработан. Можно выделить лишь несколько программных продуктов, с помощью которых можно комплексно решать задачи прогнозирования электропотребления.

PROGNOZ Platform 8 – одна из наиболее старых платформ бизнес-аналитики для создания информационных систем и применения их в качестве самостоятельного решения. В рамках данной платформы был разработан продукт «ПРОГНОЗ». Он предназначен для решения задач повышения энергетической эффективности производства на уровне руководителей, энергоменеджеров и экспертов-аналитиков промышленных компаний [118].

Данный программный продукт позволяет проводить мониторинг и анализ потребления энергоресурсов и отслеживать показатели в реальном времени. Программный комплекс включает в себя:

- облачный сервис для хранения и обработки данных;
- встроенную базу данных практических решений для решения задач прогнозирования;
- инструменты для моделирования системы и анализа экономической эффективности.

Достоинства: приемлемая точность прогнозирования электропотребления в виде графиков тренда; наличие собственного облачного сервиса для выгрузки и обработки данных, а также различных сценариев практических решений для реализации прогнозирования.

Недостатки: не специализированный продукт для решения задач прогнозирования электропотребления, имеет множество специфических особенностей. Прогнозирование электропотребления не является основной задачей, программный комплекс разработан для сопровождения планирования

электропотребления и поисков параметров энергоэффективности. Основной акцент поставлен на отслеживание параметров электропотребления в реальном времени и выявлении причин отклонений от планируемого потребления. Следовательно, данное программное обеспечение не подходит для решения комплекса задач по прогнозированию, а является больше инструментом для поддержки планирования в энергетике.

Программный комплекс «**Энергостат**» создан на базе оригинальных методов и алгоритмов. В настоящее время, практически, монополизировал нишу прогнозирования для региональных диспетчерских центров (РДУ), он внедрен и эксплуатируется более чем в 100 объектах управления электропотреблением [119]. Комплекс предназначен для решения задачи разработки специализированных программных средств для анализа и планирования режимных параметров и технико-экономических показателей энергетических предприятий и энергосистем. Достоинством программного комплекса является его открытость: методики прогнозирования опубликованы, структуры баз данных доступны, имеются встроенные средства разработки. Это позволяет пользователям разрабатывать дополнительные функции и интерфейсы, осуществлять интеграцию различных технологических задач на базе комплекса.

Программный комплекс включает специализированные средства для адаптации программных продуктов к условиям эксплуатации; методику построения сезонных кривых для долгосрочных прогнозов, модели прогнозов строятся с учетом температуры наружного воздуха. Имеется инструментарий для ведения и хранения базы данных с возможностями вывода отчетных форм в виде таблиц и схем. Дополнительно имеется собственная база данных с готовыми решениями по прогнозированию электропотребления.

Недостатком является определенная специализация программного комплекса. Для энергосистем с доминирующей коммунально-бытовой и мелкомоторной нагрузкой она малоприспособна, т.к. дает существенные погрешности прогнозирования.

MS Excel – одна из самых популярных программ. Важными ее достоинствами являются дешевизна и легкость в освоении. Однако ее использование ориентировано на «ручное» прогнозирование. При использовании этой программы невозможно применять сложные алгоритмы обработки данных, отслеживание точности прогнозов по нескольким графикам и т.д.

Программы-вычислители собственной разработки сложнее и имеют более высокую стоимость разработки, чем в MS Excel, а компания становится зависимой от одного-двух человек, разбирающихся в написанной программе. Математические программные пакеты, такие как: MATLAB, Math CAD, Scilab, SAS, SPSS, Stata сложны в работе, стоят сотни тысяч рублей за лицензии и техническую поддержку. Как уже отмечалось, разработанные на их основе системы прогнозирования энергопотребления приспособлены к прогнозированию с требуемой точностью лишь в конкретных условиях, для которых они разрабатывались, и поэтому не находят широкого применения.

Интегрированные решения типа iOPT, SAP, Oracle внедряются и адаптируются, как правило, длительное время, требуют специалистов высокой квалификации, стоимость такого решения получается высокой. Такого уровня программные решения могут позволить себе только крупные компании.

Из проведенного анализа следует вывод о необходимости разработки программы прогнозирования, функционально ориентированной для использования в масштабах региональных энергетических компаний.

Для реализации программы был выбран язык C# из-за его гибкости и возможности разработки программного обеспечения под операционную систему Windows.

Программное обеспечение должно включать несколько специфических функций: реализация возможности подгрузки оперативных данных из Microsoft Excel, в формате которого, как правило, предоставляются ретроспективные данные электропотребления, реализация нейронных сетей нескольких типов и алгоритмов их обучения. На Рис.4.11 представлена упрощённая карта кода программы.

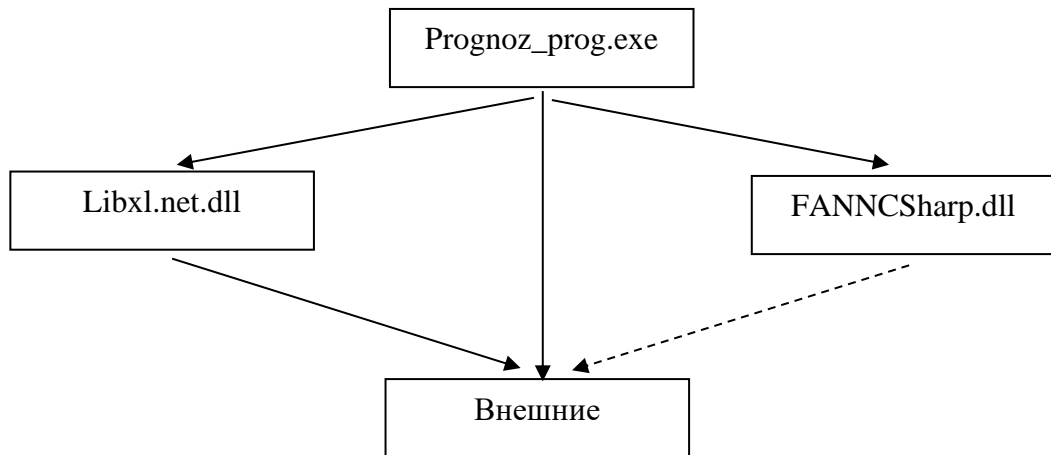


Рис.4.11. Упрощённая карта кода системы прогнозирования

Для загрузки и выгрузки данных из таблиц MS Excel использована библиотека LibXL. Библиотека позволяет читать и записывать данные в формат .xls без использования программ Microsoft Excel. Основные функции библиотеки LibXL:

```

Bookbook = new BinBook(); //объявить книгу;
book.load(filename); //открыть книгу;
Sheetsheet = book.getSheet(0); //открыть лист;
Sheetsheet = book.addSheet("Sheet"); //создать новый лист;
double data = sheet.readNum(Nostr, Nost); //считать число из str строк и st столбца;
string data = sheet.readStr(Nostr, Nost); //считать текст из str строки st столбца;
sheet.writeStr(Nostr, Nost, (string) data); //записать текст в str строку st столбца;
sheet.writeNum(Nostr, Nost, (double) data); //записать число из str строки st столбца;
book.save(namefiles); //сохранить книгу.
  
```

Для работы с нейронными сетями использованы библиотеки Fast Artificial Neural Network (FANN). Данные библиотеки позволяют работать с многослойными и каскадными нейронными сетями. Для реализации разработанной автоматизированной системы прогнозирования применялись трёх и четырёхслойные нейронные сети, с количеством нейронов в скрытых слоях от 15 до 75. Хотя данная библиотека имеет малое количество ИНС и возможных функций для алгоритмов обучения, однако она является наиболее простой в освоении и

достаточно функциональна для решения рассматриваемых задач. Основные функции библиотеки FANN:

```
Neural Netnet= new Neural Net (name Nerfann);//загрузить нейронную сеть;
Neural Netnet = new Neural Net (Network Type. LAYER, num_layers, num_input,
num_hidden1, num_hidden2, num_output);//создать нейронную сеть;
NetworkType. LAYER – тип нейронной сети;
num_layers – число слоёв;
num_input – число нейронов во входном слое;
num_hidden – число нейронов в скрытом слое;
num_output – число нейронов в выходном слое;
float [] calc_out = net.Run((float[])InputFANN1);
net. Activation Function Hidden = Activation Function. SIGMOID;//задать функцию
активации для внутренних слоёв;
net. Activation Function Output = Activation Function. SIGMOID;//задать функцию
активации для выходного слоя;
net. Train On File (namefilefann, max_iterations, iterations_between_reports,
desired_error);//обучение нейронной сети;
namefilefann – имя текстового файла с данными;
max_iterations – максимальное количество итераций;
iterations_between_reports – частота опросов процесса обучения;
desired_error – значение ошибки, при достижении которого будет прервано
обучение;
net. Save (name Nerfann); //сохранение нейронной сети
```

Описание работы программы представлено в Приложении 1.

Технология объединения наиболее эффективных нейронных сетей в многоуровневый ансамбль для получения системы прогнозирования, применимой к различным графикам нагрузок была доложена на научно-техническом конкурсе «Нейроинформатика-2016», где был получен диплом 2 степени (см. Приложение 2).

Созданный на базе описанных в работе методик, проект системы прогнозирования потребления электроэнергии, был представлен на конкурсе научно-технических работ «Энергопрорыв-2016» и «Энергопрорыв-2017», где были получены дипломы 1 степени.

В 2017 году было принято участие в конкурсе технологических стартапов «Generation-S» в секции «Электроэнергетика». Созданная система прогнозирования прошла все отборочные этапы конкурса, проект получил диплом финалиста, а также совместно с экспертами был оценен экономический эффект от применения разработанной системы прогнозирования, а проект доработан как продукт для рынка электроэнергетики.

Результатам работы были приняты к публикации в журнале *Optical Memory and Neural Networks*, входящим в список SCOPUS.

На реальных данных электропотребления, система прогнозирования была испытана в Костромской энергосбытовой компании, Филиале МРСК центра – Костромаэнерго, а также в ООО «Старк», г. Москва, инновационный центр «Сколково», в ООО «РСМ-системы», г. Москва. Полученные результаты показали практическую новизну и рациональность применения, что подтверждено удостоверением на рационализаторское предложение №2016-10-004. В настоящее время система прогнозирования проходит апробацию на постоянную эксплуатацию.

4.5. Выводы по главе 4

1. Установлено, что для повышения эффективности выполнения функций технологического и диспетчерского управления необходимо использование не только ретроспективной и текущей информации об электропотреблении, но и прогнозных упреждающих данных, как на границах ответственности региональной сетевой компании, так и на отдельных ее участках.

2. На основе анализа функционирования оптового рынка электроэнергии и мощности, а также входящих в него субрынков, определены области применения для системы принятия решений на основе использования систем прогнозирования:

- краткосрочное прогнозирование – для операций по покупке и продаже электроэнергии на ФОРЭМ;
- среднесрочное прогнозирование – для оптимизации распределения нагрузки между производителями электроэнергии;
- долгосрочное прогнозирование – для перспективного планирования и управления развитием энергетических компаний и отрасли в целом.

3. Для планово-прогнозного управления предложена структурная схема с дополнительным контуром, в котором используются информационная система прогнозирования электропотребления и система поддержки принятия решений.

4. Обоснованы структурные схемы информационных систем, построенные на основе ансамблей искусственных нейронных сетей, для отдельных и общих видов прогнозов.

5. Определена структура взаимосвязей между иерархическими уровнями АИИС КУЭ и функциями системы поддержки принятия управленческих решений на основе прогнозирования электропотребления. Данные функции определяются задачами диспетчерского управления: расчет электрических потерь, расчет режимов загрузки сетей, плановые отключения и подключения потребителей, графики ремонтных работ и т.д. Многоуровневая структура позволяет формировать интеллектуальные информационно-измерительные системы необходимого масштаба и интегрировать их с другими подсистемами АСУ электросетей.

6. Рассмотрены два вида схем организационного построения системы прогнозирования: «система прогнозирования как услуга» и «прогноз как услуга».

7. Проведен анализ предлагаемых на рынке программных продуктов для прогнозирования электропотребления и установлено, что, практически, все они являются узкоспециализированными, поэтому необходима разработка программы прогнозирования, функционально ориентированной для решения задач управления в масштабах региональных энергетических компаний. В связи с этим разработано программное обеспечение с использованием библиотеки искусственных нейронных сетей Fast Artificial Neural Network (FANN), имеющее необходимый

набор нейронных сетей и сервисных функций, которые позволяют осуществлять различные виды прогнозирования электропотребления. Испытания показали, что данная программа перспективна для применения в электросетевых или сбытовых компаниях.

8. Теоретические и практические результаты работы были апробированы в реальных производственных условиях и представлялись на специализированных конференциях и конкурсах, где получили высокие оценки.

ЗАКЛЮЧЕНИЕ

В диссертационной работе изложены научно-технические решения, направленные на совершенствование систем прогнозирования для технико-экономического планирования развитием региональной сетевой компании и для диспетчерского управления распределительными электросетями.

1. Предложена структура системы учета электроэнергии, заключающаяся в объединении подсистемы измерения и системы прогнозирования на основе ансамбля нейронных сетей. В результате у информационно-измерительной системы появляется новое свойство – возможность «предсказания» режимов загрузки электросетей для обеспечения упреждающего управления.

2. Установлено, что наиболее перспективными являются методы прогнозирования электропотребления, основанные на использовании искусственных нейронных сетей, включающие достоинства эмпирических и аналитических методов прогнозирования.

3. Проведенный анализ показал, что одиночные нейронные сети не обладают необходимой универсальностью по отношению к видам прогнозов и особенностям графиков потребления электроэнергии. В связи с этим выдвинута гипотеза, что лишь объединение различных типов нейронных сетей в ансамбли позволит решить задачи обеспечения требуемой точности для различных видов прогнозов и графиков потребления электроэнергии. Обоснована концепция построения систем прогнозирования электропотребления в виде ансамбля. Ансамбль должен иметь иерархическую структуру, формируемую из эффективных нейронных сетей, обученных таким образом, что выходные сигналы нейросетей нижнего уровня (метаданных) имели минимальную корреляцию и обеспечивали максимально возможную взаимную компенсацию погрешности отдельных прогнозов с помощью нейронной сети следующего уровня в качестве мета алгоритма.

4. Изложена методика синтеза системы прогнозирования в виде трех взаимосвязанных задач: определение входных векторов, формирование наиболее эффективных нейронных сетей, обучение нейронных сетей на ретроспективных

данных электропотребления. Исходя из принципа максимального подобия, сформированы входные векторы минимальной размерности для различных видов прогнозов.

5. Основываясь на проведенном исследовании аппроксимирующих свойств нейронных сетей и экспериментальных результатах синтезирован набор эффективных нейронных сетей, которые можно применять для самостоятельного использования и для формирования ансамблей с целью дальнейшего повышения точности и обеспечения универсальности систем прогнозирования потребления электроэнергии.

6. Разработан метод формирования ансамблей из эффективных нейронных сетей по двум критериям: по минимуму критерия, определяющего корреляции погрешностей прогнозов нейронных сетей одного уровня и по максимуму критерия, определяющего возможность взаимной компенсации этих погрешностей.

7. Установлено, что при различных структурах ансамблей для краткосрочного прогнозирования наибольшая точность достигается при использовании трехуровневого ансамбля, для среднесрочного – двухуровневого ансамбля, для долгосрочного – одиночной нейронной сети. Применение ансамблей приводит к уменьшению погрешностей прогнозирования на 20-80 % по сравнению с одиночными нейронными сетями.

8. На основе анализа функционирования оптового рынка электроэнергии и мощности, а также входящих в него субрынков, определена область применения различных видов прогнозов: краткосрочное прогнозирование – для операций по покупке и продаже электроэнергии; среднесрочное прогнозирование – для оптимизации распределения нагрузки между производителями электроэнергии; долгосрочное прогнозирование – для перспективного планирования и управления развитием энергетических компаний и отрасли в целом.

9. Определены взаимосвязи между иерархическими уровнями автоматизированной информационно-измерительной системы и подсистем прогнозирования. Многоуровневая структура позволяет формировать системы

прогнозирования необходимого масштаба и интегрировать их с другими подсистемами АСУ электросетей для поддержки принятия управленческих решений.

10. Реализована система прогнозирования в виде программы на языке С# с использованием библиотеки искусственных нейронных сетей, имеющая необходимый набор сервисных функций. Испытания показали, что данная программа перспективна для применения в электросетевых и сбытовых компаниях.

11. Теоретические и практические результаты работы были апробированы в реальных производственных условиях и представлялись на специализированных конференциях и конкурсах, где получили высокие оценки. В результате можно сделать вывод, что поставленные задачи решены.

СПИСОК ЛИТЕРАТУРЫ

1. Дорожная карта «Энерджинет» НТИ. [Электронный ресурс] Официальный сайт Министерства энергетики Российской Федерации – Режим доступа: <https://minenergo.gov.ru/node/8916> (дата обращения 23.03.2017)
2. СТО 56947007- 35.240.01.023-2009 Стандарт организации ОАО «ФСК ЕЭС» Автоматизированные информационно-измерительные системы коммерческого учета электроэнергии (АИИС КУЭ) подстанции – М.: ОАО «ФСК ЕЭС», 2009. – 27 с.
3. Староверов Б.А. Повышение эффективности системы автоматизированного контроля и учета электроэнергии за счет введения функций прогнозирования/ Б.А. Староверов, Б.А. Гнатюк // Вестник ИГЭУ. – 2013. – Вып. 5. – С. 43-46.
4. Гутовцев А.Л. Современные принципы автоматизации энергоучёта в энергосистемах/ А.Л.Гутовцев // Промышленные АСУ и контроллеры. – 2003. № 4 – С. 4 – 10
5. Описание методов прогнозирования потребления электроэнергии. [Электронный ресурс] – Режим доступа: [www.energostat.ru /about](http://www.energostat.ru/about) (Дата обращения 20.11.2017)
6. An application of non-linear autoregressive neural networks to predict energy consumption in public buildings [Электронный ресурс] // Energies. – 2016– № 9, 684p. – Режим доступа: www.mdpi.com/journal/energies
7. Бажинов А.Н. Метод прогнозирования объемов потребления электроэнергии предприятием черной металлургии на основе нейро-нечетких алгоритмов: автореф. дис. ... канд. тех. наук: 05.13.01 /А.Н.Бажинов. –Череповец, 2011 –18 с.
8. Полижаров А.С. Автоматизированная система прогнозирования электропотребления СО ЕЭС России/ А.С.Полижаров, А.В.Антонов, Б.И.Макоклюев, Э.А.Алла, А.А.Басов, О.Н.Зеленохат // Энергоэксперт.– 2010.– №6.– С.64-66.
9. Меламед М.А. Современные методы анализа и прогнозирования режимов электропотребления в электроэнергетических системах/ М.А. Меламед // Итоги науки и техники. Серия Энергетические системы и их автоматизация. – 1988. – Т.4. – С.4-111
10. Архипова О.В. Принципы и средства исследования регионально обособленного электротехнического комплекса с позиций системного

- анализа // Омский научный вестник. – 2020. – №. 3 (171). DOI: 10.25206/1813-8225-2020-171-42-46.
11. Руденко Ю.Н. Автоматизация диспетчерского управления в электроэнергетике / Под общей ред. Ю.Н. Руденко и В.А. Семенова. – М.: Издательство МЭИ, 2000. – 648 с.
 12. Шумилова Г.П. Прогнозирование электрических нагрузок при оперативном управлении электроэнергетическими системами на основе нейросетевых структур / Г.П. Шумилова, Н.Э. Готман, Т.Б. Старцева. – Сыктывкар, 2008. КНЦ УрО РАН. – 77 с.
 13. Филиппова Т.А. Модели и методы прогнозирования электроэнергии и мощности при управлении режимами энергетических систем: монография / Т.А. Филиппова, А.Г. Русина, Ю.В. Дронова. – Новосибирск: Изд-во НТГУ, 2009. – 368 с.
 14. Arkhipova O.V., 2021. Principles of system analysis for sustainable electric power supply to agro-industrial complexes operating in energy isolated territories, in: IOP Conference Series: Earth and Environmental Science. IOP Publishing Ltd. <https://doi.org/10.1088/1755-1315/723/5/052032>.
 15. Дуброва Т.А. Статистические методы прогнозирования в экономике. / Т.А. Дуброва. – Московский международный институт эконометрики, информатики, финансов и права. – М., 2004. – 60 с.
 16. Системный анализ в управлении: Учеб. пособие / В.С. Анфилатов, А.А. Емельянов, А.А. Кукушкин. Под ред. А.А. Емельянова. - М.: Финансы и статистика, 2002 - 368 с.
 17. Тихонов Э.Е. Прогнозирование в условиях рынка / Э.Е. Тихонов. – Невинномысск, 2006. – 221 с.
 18. Catalao J. xtrapolation, Interpolation and Smoothing of Stationary Time Series/ J. Catalao [at al.] // 6th WSEAS international conference on Neural networks, USA, Stevens Point. – 2005. – P. 80-83.
 19. Макоклюев Б.И. Анализ и планирование электропотребления / Б.И. Макоклюев. – М.: Энергоатомиздат, 2008. – 296 с.
 20. Кильдишаев Г.С. Анализ временных рядов и прогнозирование / Г.С. Кильдишаев, А.А. Френкель // М.: Статистика, 1979.
 21. Чучуева И. А. Сезонно-регрессионная модель прогнозирования в решении задачи прогнозирования цен РСВ (рынок на сутки вперед) / И. А. Чучуева, Ю.Н. Павлов // Энерго-Info. 2009. №4. С. 46 – 49.

22. Wiener N. Extrapolation, Interpolation and Smoothing of Stationary Time Series / N. Wiener // Wiley, New York, 1949.
23. Singh S. Pattern Modelling in Time-Series Forecasting // Cybernetics and Systems-AnInternational Journal. 2000, - Vol. 31, No. 1. - P. 49 – 65
24. Fernández-Rodríguez F., Sosvilla-Rivero S., Andrada-Félix J. Nearest Neighbour Predictions in Foreign Exchange Markets // Fundacion de Estudios de Economia Aplicada [электронный ресурс]. - 2002, No.5. 36 p. URL: <http://www.fedea.es/pub/Papers/2002/dt2002-05.pdf> (дата обращения 20.11.2016)
25. Адаптивные фильтры: Пер. с англ./ Под ред. Е.Ф.Н. Коуэна и П.М. Гранта. – М.: Мир, 1988. – 392 с.
26. Осовский С. Нейронные сети для обработки информации / С. Осовский. – Изд-во: Финансы и статистика, 2002. – 344 с.
27. Оскина Л.К. Коммерческий и технический учет электрической энергии на оптовом и розничном рынках: теория и практические рекомендации / Л.К. Оскина. – СПб.: Политехника. 2005. – 360 с.
28. Глебов А.А. Модель краткосрочного прогнозирования электропотребления с помощью нейро-нечетких систем: дис. ... канд. техн. наук.: 05.13.10 – Управление в социальных и экономических системах / Астраханский государственный университет. – Астрахань, 2006. – 112 с.
29. Комашинский В.И. Нейронные сети и их применение в системах управления и связи /В.И.Комашинский, Д.А.Смирнов – М.: Горячая линия – Телеком, 2003 – 94 с.
30. Шутов Е.А. «Проблемы прогнозирования потребления электроэнергии» / Е.А. Шутов, Д.Е. Бабинович, Т.Н. Кириллова // Проблемы энергетики. – 2010. – 4/1. – №3 – С.49-59.
31. Basaran F.U. A New Approach for the Short-Term Load Forecasting with Autoregressive and Artificial Neural Network Models/ F.U. Basaran, M. Kurban// International Journal of Computational Intelligence Research. – 2007.– No.3.– P. 66 - 71.
32. Терехов В.А., Ефимов Д.В., Тюкин И.Ю. Нейросетевые системы управления. Кн.8. – М.: ИПРЖР, 2002. – 408 с.
33. Chester D. Why two hidden are better than one // IEEE Int. Joint. Conf. Neural Networks. IJNN'90.1990. pp. 265-268.

34. Терехов С. А. Гениальные комитеты умных машин // Научная сессия МИФИ-2007. IX Всероссийск "Нейроинформатика-2007": Лекции по нейроинформатике. Часть 2. — М.: МИФИ, 2007. — С. 11–42.
35. Гончаров М. Ансамбли моделей. [Электронный ресурс]. URL: <http://www.businessdataanalytics.ru/download/ModelEnsembles.pdf> (дата обращения: 12.04.2018).
36. Сигорский В.П. Математический аппарат инженера. – Киев: Техника, 1975.–768 с.
37. Куликов Е. И. Прикладной статистический анализ. — М.: Горячая линия–Телеком, 2008. — 464 с.
38. Серебряков Н.А. Применение адаптивного ансамблевого нейросетевого метода для краткосрочного прогнозирования электропотребления электротехнического комплекса районных электрических сетей // Омский научный вестник. – 2021. – № 1 (175). – С. 39–45. – DOI: 10.25206/1813-8225-2021-175-39-45.
39. Тулупьев, А. Л. Байесовские сети. Логиковероятностный подход / А. Л. Тулупьев, С. И. Николенко, А. В. Сироткин // Наука. – 2006. – 608 с
40. Колмогоров А.Н. О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного/ А.Н. Колмогоров // Докл. АН СССР. – 1958. – Т. 114, № 5. – С. 953-956
41. Lorentz G.G. Approximation of function. Holt. Reinhart and Winston. N.-Y. 1965
42. Гробарь А.Н. Обобщённая аппроксимационная теорема и вычислительные возможности нейронных сетей //Сибирский журнал вычислительной математике. – 1998. Т.1, №1, – С. 12-24
43. Бутырский Е.Ю., Кувалдин И.А., Чакалин В.П. Аппроксимация многомерных функций //Научное приборостроение. – 2010.Е.20, №2. – С. 82-92
44. Надтока И.И. Нейросетевая модель прогнозирования электропотребления с учетом освещенности на территориях операционных зонрегиональных диспетчерских управлений/ И.И. Надтока, С.О. Губский, И.Е. Шепелев // Изв. вузов. Электромеханика, 2012. – №2. – С. 18-21.
45. Губский С.О. Краткосрочное прогнозирование электропотребления в операционной зоне регионального диспетчерского управления с учетом

- фактора освещенности: автореф. дис. ... канд. тех. наук: 05.14.02 / С.О. Губский– Новочеркасск, 2012.– 19 с.
46. Серебряков, Н.А. Анализ факторов, влияющих на совокупное электропотребление гарантирующего поставщика // Вестник Иркутского государственного технического университета. – 2020. – Т. 24. – № 2. – С. 366–381. – DOI: <https://doi.org/10.21285/1814-3520-2020-2-366-381>
 47. Аль Зихери Б.М. Повышение точности краткосрочного прогнозирования электрической нагрузки потребителей региона с учетом метеофакторов на основе метода опорных векторов: дис. канд. тех. наук: 05.14.02 / Б.М. Аль Зихери–Новочеркасск, 2015. – 181с.
 48. Макоклюев Б.И. Учет влияния метеорологических факторов при прогнозировании электропотребления энергообъединений / Б.И.Макоклюев, В.Ф. Еч // Энергетик. – 2004. – №6
 49. Староверов Б.А. Повышение точности оперативных прогнозов потребления электроэнергии с помощью нейронных сетей за счет объединения процессов классификации и аппроксимации суточных профилей / Б.А. Староверов, В.А. Изотов, М.А. Мормылев // Вестник ИГЭУ. 2007, Вып. 4. С. 91 – 93.
 50. Гофман А.В. Повышение точности краткосрочного и оперативного прогнозирования электропотребления энергосистемы с применением искусственной нейронной сети / А.В. Гофман, А.С. Ведерников, Е.С. Ведерникова // Электрические станции, 2012. – №7. – С. 36-41.
 51. Надтока И.И. Прогнозирование электропотребления с учетом температуры воздуха и естественной освещенности для региональных диспетчерских управлений / И.И. Надтока, А.В. Демура, С.О. Губский, А.Я. Ваколюк, В.В. Горбачев// Вестник СамГТУ.–2012. – №1(33) – С.163-168.
 52. Алексеева И.Ю. Прогнозирование электропотребления с использованием метода искусственных нейронных сетей/ И.Ю.Алексеева, А.С. Ведерников, М.О. Скрипачев // Сер.Технические науки. Вестник СамГТУ. – Самара: ГОУ ВПО «СамГТУ», 2010. – с. 135 - 138.
 53. Методические указания по определению влияния температурного фактора на потребление электрической энергии (мощности). Распоряжение ОАО «СО ЕЭС» от 15.12.2010 №75р. – М.,2010.
 54. Соломкин А.В. Краткосрочное прогнозирование потребления электроэнергии с помощью нейросетевых методов // Электроника и информационные технологии [электронный ресурс]. 2011, №1. 5 с.

- URL: http://fetmag.mrsu.ru/2009-3/pdf/Forecasting_electricity_consumption.pdf (дата обращения 21.12.2015).
55. Kumar M. Short-term load forecasting using artificial neural network techniques: Thesis for Master of Science degree in Electrical Engineering. / М.Кумар// India, Rourkela, National Institute of Technology/ 2009.48p.
 56. Хомутов С.О. Влияние метеорологических факторов на режим потребления электроэнергии группы точек поставки электроэнергии сельскохозяйственных товаропроизводителей / С.О. Хомутов, Н.А. Серебряков // Вестник Алтайского государственного аграрного университета. – 2019. – № 5 (175). – С. 148–153.
 57. Jolliffe I.T. Principal Component Analysis, Series: Springer Series in Statistics. – 2nd ed. – Springer, NY, 2002. – 487 p.
 58. Соломахо К.Л. Применение метода главных компонент для прогнозирования объемов электропотребления энергосбытового предприятия: дис. ... канд. тех. наук: 05.09.03 /К.Л. Соломахо. –Челябинск, 2015 –141 с.
 59. Многофакторное прогнозирование потребления электроэнергии в промышленном и бытовом секторах / Т. Кирилова [и др.] // Энергорынок2009, –№11.– С. 40-43.
 60. Белов К.В. Автоматизированная система прогнозирования потребления электрической энергии предприятием / Белов К.В. // Наука и образование. – М.: МГТУ им Н.Э. Баумана, 2010.–№ 12. – с. 30-35
 61. Жилин Б.В. Прогнозирование месячного электропотребления по цехам химического производства на основе структурно-топологической динамики N-распределения / Б.В. Жилин, О.Е. Лагуткин // Новомосковск, 1993.
 62. Тимченко В.Ф. Прогнозирование режимов электропотребления нерегулярных дней/ В.Ф. Тимченко, А.М. Меламед, А.М. Скрипко//Электрические станции. –1987. –№ 5.–С. 52-57.
 63. Чучуева И. А. Модель экстраполяции временных рядов по выборке максимального подобия/ И.А. Чучуева // Информационные технологии, 2010.–№12– С. 43-47.
 64. Староверов Б.А. Определение наиболее перспективных нейронных сетей и способов их обучения для прогнозирования электропотребления/ Б.А. Староверов, Б.А. Гнатюк // Вестник ИГЭУ. – 2015. – №6. – С. 1-6.

65. Хайкин С. Нейронные сети: полный курс / С. Хайкин. – М.: ООО «И. Д. Вильямс», 2006. – 1104 с.
66. Haykin S. Neural networks, a comprehensive foundation / S. Haykin – N.Y.: Macmillan College Publishing Company – 1994.
67. Вапник В. Н. О равномерной сходимости частот появления событий к их вероятностям // Теория вероятностей и ее применения / В.Н. Вапник, А.Я. Червоненкис– 1971. – Т. 16, № 2. – С. 264-280.
68. Вапник В. Н. Теория распознавания образов / В.Н. Вапник, А.Я. Червоненкис – М.: Наука, 1974 г.
69. Hush D. Progress in supervised neural networks / D. Hush, B. Horne // IEEE Signal Processing Magazine, 1993, January. – Pp. 359-366.
70. Горожанина Е.И. Нейронные сети. Учебное пособие. [Текст] / Е.И. Горожанина. – Самара. ФГБОУ ВО ПГУТИ, 2017 – 84 с.
71. Боровиков В.П. Нейронные сети. Statistica Neural Networks. Методология и технологии современного анализа данных / В.П. Боровиков 2-е изд., перераб. и доп. — М.: Горячая линия - Телеком, 2008. — 392 с.
72. Медведев В. С., Потемкин В. Г. Нейронные сети. МАТЛАБ 6. / Под общ.ред. В. Г. Потемкина. – М.: ДИАЛОГ- МИФИ, 2001. – 630 с.
73. Ларько, А. А. Оптимизация размера нейросети обратного распространения [Электронный ресурс] / URL: <http://www.sciteclibrary.ru/rus/catalog/pages/8621.html> (дата обращения 20.02.2018).
74. Han C. An intrusion detection system based on neural network / C. Han, Y. Li, D. Yang, Y. Hao // Proceedings of Mechatronic Science. Electric Engineering and Computer (MEC). – 2011.– p. 2018-2021.
75. Bukhtoyarov V. Neural Networks Ensembles Approach for Simulation of Solar Arrays Degradation Process/V. Bukhtoyarov, E. Semenkin // Hybrid Artificial Intalligent Systems. Lecture Notes in Computer Science. – 2012. – vol. 7208. – p. 186-195.
76. Башмаков А.И. Интеллектуальные информационные технологии: Учеб. Пособие/А.И. Башмаков, И.А. Башмаков – М.: Изд-во МГТУ им. Н.Э. Баумана, 2005. – 304с.
77. Лихачева Г.Н. Информационные технологии: Учебно-практическое пособие. / Г.Н. Лихачева, М.С. Гаспарян – М.: Изд. центр ЕАОИ. – 2007. – 189 с.
78. Растрингин Л.А. Адаптация сложных систем. / Л.А. Растрингин – Рига: Зинатне, 1981. – 375 с.

79. Ясницкий Л.Н. Введение в искусственный интеллект. / Л.Н. Ясницкий–М.: Издательский центр «Академия», 2005. – 176 с.
80. Люгер Дж. Ф. Искусственный интеллект. / Дж. Ф. Люгер– Изд. 4-е. – М., 2003. – 485 с.
81. Freund Y. Experiments with a new boosting algorithm / Y. Freund, R. E. Schapire // International Conference on Machine Learning. – 1996. –p. 148 - 156.
82. Morariu N. A neural network model for time series forecasting/ N. Morariu, E. Iancu, S. Vlad // Romanian Journal of Economic Forecasting. 2009, No.4. p. 213 – 223.
83. Wolpert D. H. Stacked generalization. Neural Networks, 5 / D. H. Wolpert, – 1992. – p. 214–259.
84. Menahem, Eitan, LiorRokach, Yuval Elovici. Troika–An improved stacking schema for classification tasks // Information Sciences 179.24 (2009): 4097-4122.
85. Скиена С. Алгоритмы. Руководство по разработке. / С. Скиена – 2-е изд.: Пер с англ. – СПб.: БХВ-Петербург, 2011. – 720 с.
86. Breiman L. Bagging predictors / L. Breiman. – Machine learning 24.2 –1996. – p. 123-140.
87. Андронов Ю.В. Исследование применения ансамблей нейронных сетей для повышения качества решения задач регрессии / Ю.В. Андронов, А.В. Стрекалов // Разработка нефтяных и газовых месторождений. – 2013. –Т.13, №1. – С. 50-55.
88. Гольцев А.Д. Нейронные сети с ансамблевой организацией. / А.Д. Гольцев. – Киев: Наукова думка, 2005. 200 с.
89. Курейчик В.В. Эволюционные, синергетические и гомеостатические методы принятия решений: монография / В.В. Курейчик. – Таганрог: Изд-во ТРТУ, 2001.
90. Назаров А.В. Нейросетевые алгоритмы прогнозирования и оптимизации систем / А.В.Назаров, А.И. Лоскутов – СПб.: Наука и Техника, 2003. – 384 с.
91. Каширина И.Л. О методах формирования нейросетевых ансамблей в задачах прогнозирования финансовых временных рядов /И.Л. Каширина. – Вестник ВГУ, Серия: Системный анализ и информационные технологии. – 2009. – №2. – с.116-119.

92. Kovalev, V., Arkhipova, O., Paramzin, A., 2020. Renewable energy sustainability in terms of systems analysis, in: E3S Web of Conferences. EDP Sciences. <https://doi.org/10.1051/e3sconf/202020802008>.
93. Staroverov B.A. Universal energy consumption forecasting system based on neural network ensemble / B.A. Staroverov, B.A. Gnatyuk // Optical Memory and Neural Networks – July 2016 – Issue 3 – pp 198–202
94. Староверов Б.А. Алгоритм формирования ансамбля нейронных сетей для информационной системы прогнозирования электропотребления// Информационно-экономические аспекты стандартизации и технического регулирования, 2019. №1(47). Режим доступа: ([http://iea.gostinfo.ru/magazine_2019_01\(47\).html](http://iea.gostinfo.ru/magazine_2019_01(47).html)).
95. Политика инновационного развития, энергосбережения и повышения энергетической эффективности ОАО «Россети» [Текст] // Протокол совета директоров ОАО «Россети» № 150 от 23.04.2014. – Москва, 2014. – 37 с.
96. Arkhipova, O.V., Kovalev, V.Z., Khamitov, R.N., 2019. Methodology of modeling regionally isolated electrotechnical complex [Методика Моделирования регионально обособленного электротехнического комплекса]. Bulletin of the Tomsk Polytechnic University, Geo Assets Engineering 330, 173–180. <https://doi.org/10.18799/24131830/2019/1/63>.
97. Камаев, М. Вопросы импортозамещения и импортнезависимости [Текст] / М. Камаев // Автоматизация и ИТ в энергетике. – 2016, №2(79). – с. 12-16.
98. Техническая политика ОАО «МРСК Центра» в области информационных технологий [Текст] // Протокол совета директоров ОАО «МРСК Центра» № 16/10 от 30.07.2010.– М., 2010. – 102 с.
99. Типовая программа модернизации и расширения системы сбора и передачи информации на подстанциях МРСК[Текст] от 19.03.2010– М., 2010.
100. Положение ОАО «Россети» о единой технической политике в электросетевом комплексе [Текст] // Протокол совета директоров ОАО «Россети» № 138 от 23.10.2013. – М., 2013. – 196 с.
101. Автоматизированная система диспетчерского управления центра управления сетями филиала ОАО «МРСК Центра» – «Костромаэнерго» [Текст] // ООО «СИСТЕЛ АВТОМАТИЗАЦИЯ» ИСТА.425270.064ТП. – М., 2006. – 57 с.
102. Энергетическая стратегия России на период до 2030 [Текст] // Распоряжение Правительства Российской Федерации №1715-р от 13.11.2009. – М., 2009. – 144с.

103. Оптимальные решения для автоматизации подстанций: интегрированные системы АСДТУ (АИИС КУЭ). – Энергоэксперт. – 2009, №6. – с. 25-28
104. Автоматизация подстанций для построения интеллектуальных электросетей [Электронный ресурс]. – Режим доступа: [cisco.com> web/RU/downloads/broch...po...podstancij.pdf](http://cisco.com/web/RU/downloads/broch...po...podstancij.pdf) (дата обращения: 18.04.2019)
105. Автоматизация учёта энергоресурсов: ИИС «Пирамида» [Электронный ресурс]. – Режим доступа: <http://www.sicon.ru/prod/aiis/> (дата обращения: 19.04.2017)
106. АИИС "Матрица" [Электронный ресурс]. – Режим доступа: <http://www.matritca.ru/produksiya/aiis-kue-askue> (дата обращения: 19.04.2019)
107. АИИС КУЭ РРЭ интеллектуальные системы учета энергоресурсов КСУЭР [Электронный ресурс]. – Режим доступа: <http://www.prosoftsystems.ru/solution/show/aiis-kuje-orje> (дата обращения: 19.04.2019)
108. Стофт С. Экономика энергосистем. Введение в проектирование рынков электроэнергии: Пер. с англ. / С. Стофт – М.: Мир, 2006. – 623 с., ил.
109. Федеральный закон от 03 апреля 1996 № 28-ФЗ «Об энергосбережении».
110. Федеральный закон от 26 марта 2003 г. N 35-ФЗ "Об электроэнергетике" (с изменениями и дополнениями).
111. Бахтеева, Н.З. Конкурентный оптовый рынок электроэнергии и мощности: состояние и новые вызовы / Н.З. Бахтеева, Л.А. Галимзянов, З.В. Шацких // Проблемы энергетике. – 2016. – № 5. – С. 70–78.
112. Трафименко С.А. Срочный рынок в электроэнергетике – состояние и перспективы/ С.А. Трафименко / Энерго Рынок. – Москва, 2011. – Вып. 4 – с.35-40
113. Постановление правительства РФ от 29.12.2011 N 1178 (ред. от 07.05.2017) «О ценообразовании в области регулируемых цен (тарифов) в электроэнергетике». М., 2017. – 138 с.
114. Постановление правительства РФ № 442 от 04.05.2012 (ред. от 11.05.2017) «О функционировании розничных рынков электрической энергии, полном и (или) частичном ограничении режима потребления электрической энергии». [Электронный ресурс] – Режим доступа: www.consultant.ru
115. Староверов Б.А. Применение нейросетевых информационных систем прогнозирования для принятия решений по оптовой закупке

- электроэнергии // Информационно-экономические аспекты стандартизации и технического регулирования. – 2021. – № 4(62). – С.65-70.
116. Веб-сайт компании Mathworks. Pricing and Licensing – MATLAB & Simulink. [Электронный ресурс]. – Режим доступа: <https://de.mathworks.com/pricing-licensing.html?prodcode=ML&intendeduse=com> (дата обращения: 18.06.2019)
 117. Веб-сайт компании Neuro Solutions. Neural Network Software, Artificial Intelligence, Data Mining, Distributed Processing, Parallel Computing. [Электронный ресурс]. – Режим доступа: <http://www.neurosolutions.com/neurosolutions/> (дата обращения: 18.06.2019)
 118. Веб-сайт компании Прогноз. [Электронный ресурс]. – Режим доступа: <http://www.prognoz.ru/platform> (дата обращения: 20.07.2019)
 119. Веб-сайт компании Энергостат. [Электронный ресурс]. – Режим доступа: <http://energostat.ru> (дата обращения: 20.07.2019)

ПРИЛОЖЕНИЕ 1

Результаты экспериментальных исследований нейронных сетей различного типа

Вход (Input): по данным потребления электроэнергии за три года,

$\{[X_{-1}X_1X_2 \dots X_{N-1}]; [X_{-2}X_{-1}X_1 \dots X_{N-2}]; [X_{-3}X_{-2}X_{-1} \dots X_{N-3}]; [X_{-4}X_{-3}X_{-2} \dots X_{N-4}]; [X_{-5}X_{-4}X_{-3} \dots X_{N-5}]\}$ – Данные часового потребления электроэнергии (со сдвигом на пять дней)



$[1\ 2\ 3\ 4 \dots 24]; [1\ 2\ 3 \dots 24]; [1\ 2\ 3 \dots 24]; [1\ 2\ 3 \dots 24]; [1\ 2\ 3 \dots 24];$ – Временная часовая градация

$[1\ 2\ 3\ 4\ 5\ 6\ 7]$ – Временная дневная градация, соответствующая данным целевого ряда (1 – понедельник; 7 – воскресенье)



$[1\ 2\ 3\ 4\ 5\ 6\ 7\ 8\ 9\ 10\ 11\ 12]$ – Временная месячная градация, соответствующая данным целевого ряда (1 - январь; 12 - декабрь)

Выход (Target): $\{[X_1\ X_2\ X_3 \dots X_N]\}$ – данные почасового потребления энергии



Нейросеть с прямым распределением и задержкой по времени (*Feed-forward distributed delay*)




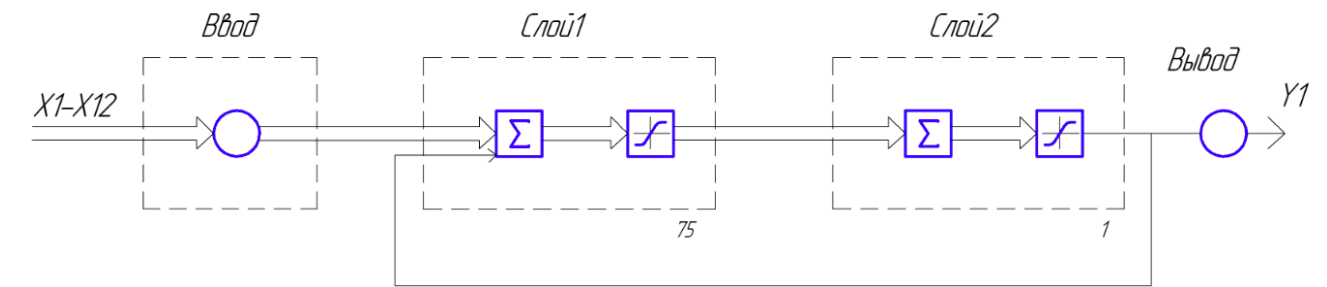
Нейросеть Элмана (Elmanbackprop)




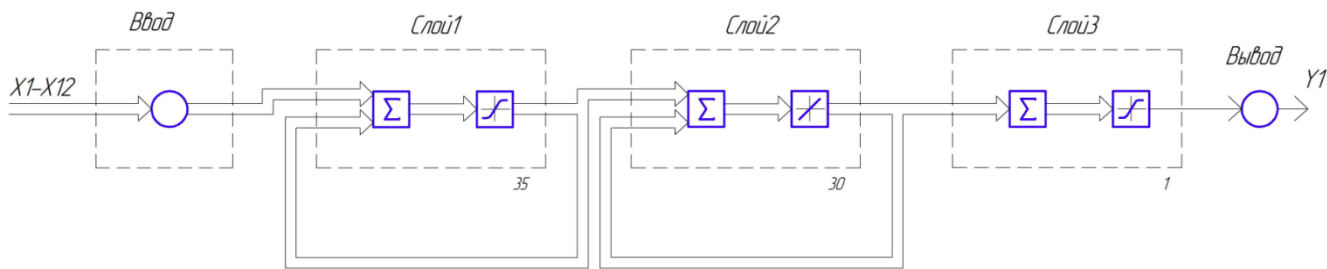
Нейросеть с прямым распределением (Feed-forwardbackprop)



Рекуррентная многослойная нейросеть (NARX)



Трехслойная Нейросеть Элмана (Elmanbackprop(Pureli))



ПРИЛОЖЕНИЕ 2

Описание работы программного обеспечения для прогнозирования электроэнергии на основе ансамбля ИНС

После запуска программы отображается меню:

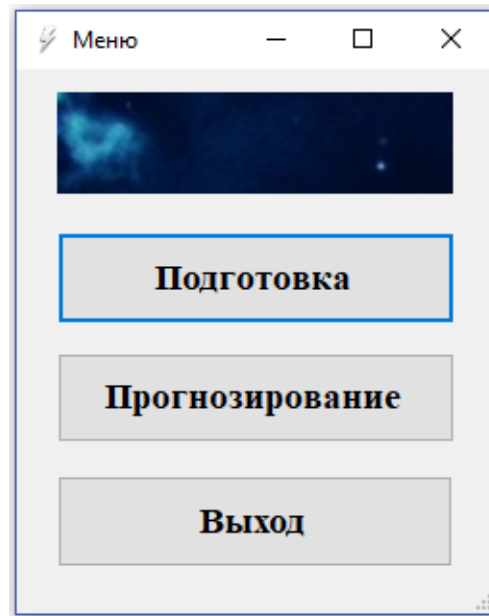


Рис.П2.1. Главное меню

Основное меню содержит три клавиши-перехода в следующие разделы:
 “Подготовка” – служит для перехода в раздел по обучению нейронной сети.
 “Прогнозирование” – служит для перехода в раздел прогнозирования.
 “Выход” – закрывает программу.

Меню обучение – служит для обучения нейронных сетей, используемых для прогнозирования электропотребления, в меню прогнозирование.

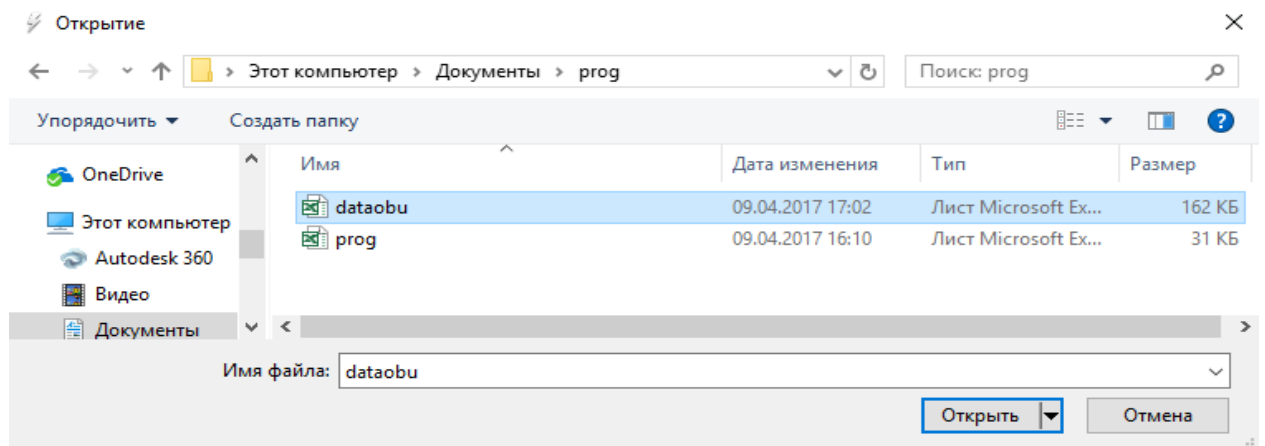


Рис.П2.2. Выбор файлов для произведения обучения ИНС

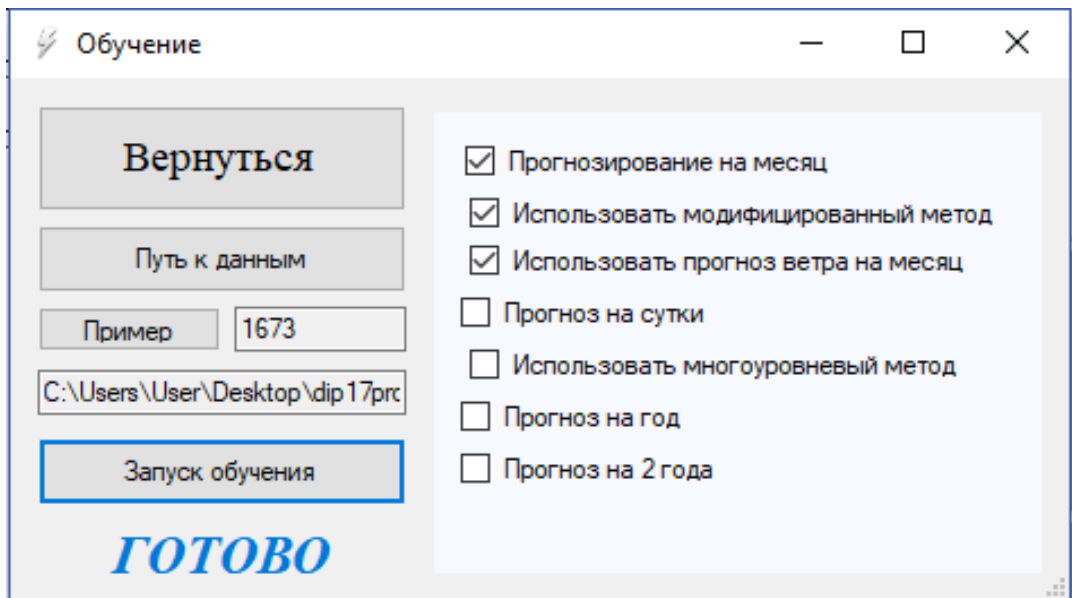


Рис.П2.3. Меню обучения нейронных сетей

Данное меню имеет следующие элементы управления:

Клавиша “Вернуться” – служит для перехода обратно в меню.

Клавиша “Путь к данным” – позволяет выбрать данные для проведения обучения.

Данные должны содержаться в формате .xls, и могут быть представлены в двух вариантах:

Посуточные данные, используемые в прогнозировании на месяц, на год и на два года вперёд.

Для прогнозирования на месяц желательно иметь обучающий массив данных объёмом не менее двух лет, для прогнозирования на год и на два года объём данных должен превышать 1500 дней (более четырёх лет). Формат данных представлен на рисунке 6.4.

Почасовые данные, используются в прогнозировании на сутки вперёд, также возможно использовать их при прогнозировании на год, два года, и на месяц вперёд с ограничениями.

Данные представлены в виде таблицы, где в первой строке указывается название колонок:

первые три колонки аналогичны посуточным данным (число, месяц, год);

в четвёртой колонке указывается час, в цифрином обозначении от 1 до 24.

в пятой колонке указывается потребление за час, соответствующее календарным данным (часу, числу, месяцу, году).

После загрузки данных в первом окне отобразится количество суток в загруженных данных, во втором путь к данным, после отображения данной информации данные будут готовы к дальнейшей работе, в случае если данные не загрузились, будет выведена ошибка во втором табло.

	A	B	C	D	E	F	G
					Объём отпуска электроэнергии в сеть филиала, кВт*ч		
1	Период_дата	мес	год	№час			
2	1	1	2014	1	293 626		
3	1	1	2014	2	296 533		
4	1	1	2014	3	286 065		
5	1	1	2014	4	271 740		
6	1	1	2014	5	252 568		
7	1	1	2014	6	243 851		
8	1	1	2014	7	240 902		
9	1	1	2014	8	249 232		
10	1	1	2014	9	255 946		
11	1	1	2014	10	262 147		
12	1	1	2014	11	286 339		
13	1	1	2014	12	295 522		
14	1	1	2014	13	296 007		
15	1	1	2014	14	275 248		
16	1	1	2014	15	280 357		
17	1	1	2014	16	292 248		
18	1	1	2014	17	291 687		
19	1	1	2014	18	317 180		
20	1	1	2014	19	319 854		

Рис.П2.4. Формат почасовых данных

Перед проведением обучения требуется задать параметры обучения указав нужные флажки:

Флажок “Прогнозирование на месяц” – при установлении данного флажка во время обучения будет обучена нейронная сеть для прогнозирования на месяц с параметрами, зависящими от загруженных данных.

Флажок “Использование модифицированного метода” – данный флаг относится к прогнозированию на месяц, при установлении этого флага будет использован изменённый метод обучения, у которого прогноз на первые дни месяца будет иметь меньшую ошибку. Минусами данного метода является большое время обучение и требовательность к ресурсам.

Флажок “Прогнозирование на сутки” – при установлении данного флажка во время обучения будет обучена нейронная сеть для прогнозирования на сутки вперёд, если были загружены почасовые данные потребления.

Флажок “Использовать многоуровневый метод” – данный флаг относится к прогнозированию на сутки, данный метод увеличивает точность прогнозирования, но в разы повышает время на обучение.

Флажок “Прогнозирование на год” – при установлении данного флажка во время обучения будет обучена нейронная сеть для прогнозирования на год вперёд, для проведения данного обучения требуется не менее 1500 данных посуточного потребления или 36000 данных почасового потребления, в ином случае программа выдаст сообщение об ошибке.

Клавиша “Запуск обучения” - после выбора и установки требуемых флагов требуется запустить обучение нейронной сети, обучение будет проводиться длительное время и по его окончанию, будет отображена надпись “ГОТОВО”.

Затем необходимо перейти во вкладку “Прогнозирование” через основное меню.

Прогнозирование

Вернуться Пример данных

Модифицированная нейросеть готова Нейросеть готова

Прогноз на месяц Отобразить Сохранить Прогноз на сутки Отобразить Сохранить Прогноз на год Прогноз на 2 года

Число	Месяц	Прогноз
1	Декабрь	9037475
2	Декабрь	8614117
3	Декабрь	8489698
4	Декабрь	7923075
5	Декабрь	9001382
6	Декабрь	9140623
7	Декабрь	9351020
8	Декабрь	8614990
9	Декабрь	8587148
10	Декабрь	8540326
11	Декабрь	8368837
12	Декабрь	9319286
13	Декабрь	9417474
14	Декабрь	9338810
15	Декабрь	9124549
16	Декабрь	9314642
17	Декабрь	8553992
18	Декабрь	7746853
19	Декабрь	8567762
20	Декабрь	9612665
21	Декабрь	8460619

Число	Месяц	Час	Потребление
13	Февраль	1	280138,4
13	Февраль	2	276414,2
13	Февраль	3	272967,3
13	Февраль	4	268607,8
13	Февраль	5	272681,9
13	Февраль	6	287338
13	Февраль	7	307866,5
13	Февраль	8	337547,8
13	Февраль	9	364495,8
13	Февраль	10	381791,4
13	Февраль	11	387418,2
13	Февраль	12	384885,5
13	Февраль	13	373862,3
13	Февраль	14	370397,6
13	Февраль	15	369626,7
13	Февраль	16	366186,2
13	Февраль	17	366608,8
13	Февраль	18	378577,7
13	Февраль	19	390420
13	Февраль	20	388176,1
13	Февраль	21	376128,7

Месяц	Потребление
Октябрь	232374656
Ноябрь	244341952
Декабрь	264106736
Январь	257507568
Февраль	231678784
Март	241134624
Апрель	222287792
Май	205196000
Июнь	190952480
Июль	193459616
Август	203002768
На год	2691243264
Октябрь	228108144
Ноябрь	241659776
Декабрь	261296224
Январь	272170848

Рис.П2.5. Меню прогнозирования

Клавиша “Прогноз на месяц” – служит для запуска прогнозирования на месяц. При нажатии данной клавиши будет открыто меню выбора данных для прогнозирования. Данные должны храниться в формате .xls.

Формат данных должен соответствовать формату данных для обучения, только если используется прогноз погоды, данные прогноза погоды должны следовать ниже основных данных пропуская колонку потребление. Для прогноза на месяц требуется не менее 35 суток данных потребления и в случае использования переменной погоды дополнительно 31 значение прогноза погоды в дополнении к 35 суткам архива погоды.

Для прогноза на месяц возможно использовать почасовые данные, но данных будет требоваться в 24 раза больше.

Результаты прогнозирования представляются в таблице, где показано в первом столбце календарное число, на которое был произведён прогноз, во втором месяц, в третьем прогноз потребления для данной даты.




Рис.П2.6. Окно прогноза на месяц

Число	Месяц	Прогноз
12	Декабрь	9319286
13	Декабрь	9417474
14	Декабрь	9338810
15	Декабрь	9124549
16	Декабрь	9314642
17	Декабрь	8553992
18	Декабрь	7746853
19	Декабрь	8567762
20	Декабрь	9612665
21	Декабрь	8460619
22	Декабрь	8715940
23	Декабрь	8403952
24	Декабрь	8162305
25	Декабрь	8029890
26	Декабрь	8788721
27	Декабрь	8451951
28	Декабрь	8562206
29	Декабрь	8606654
30	Декабрь	8293221
31	Декабрь	8390274
Прогноз на	31 день =	269530455,5

Рис.П2.7. Таблица прогноза на месяц

В последней строке указывается сумма прогноза потребления за 31 день.

После произведения прогноза для графического отображения прогноза можно построить график потребления электроэнергии, с помощью нажатия клавиши “Отобразить”. В

появившемся окне слева отображается таблица прогноза потребления, справа график потребления.

Клавиша “Прогноз на сутки” – служит для запуска прогнозирования на сутки вперёд. При нажатии данной клавиши будет открыто меню выбора данных для прогнозирования. Данные также должны быть представлены в виде почасового потребления храниться в формате .xls. Формат данных должен соответствовать формату данных для обучения данного типа прогнозирования. Для прогноза на сутки требуется почасовых данных не менее 120 значений (5 суток).

Число	Месяц	Час	Потребление
13	Февраль	5	280344,4
13	Февраль	6	292873,7
13	Февраль	7	318443,6
13	Февраль	8	381876,2
13	Февраль	9	401912,3
13	Февраль	10	411726,3
13	Февраль	11	403427,3
13	Февраль	12	401055,2
13	Февраль	13	390082,8
13	Февраль	14	385923,9
13	Февраль	15	379316,2
13	Февраль	16	377343,2
13	Февраль	17	381137,9
13	Февраль	18	391209
13	Февраль	19	401644,4
13	Февраль	20	398903,3
13	Февраль	21	384976,5
13	Февраль	22	372844,7
13	Февраль	23	344051,1
13	Февраль	24	312495,8
Прогноз на	24	день =	8513675,96875

Рис.П2.8. Таблица прогноза на сутки

Данный прогноз можно проводить если во втором окне указано что нейронная сеть загружена, если в данном окне отображено что нейронная сеть отсутствует, требуется вернуться в меню обучения и дообучить нейронную сеть.

Результаты прогнозирования представляются в таблице, где показано в первом столбце календарное число, на которое был произведён прогноз, во втором месяц, в третьем час, в четвёртом прогноз потребления для данного времени.

После произведения прогноза для графического отображения прогноза можно построить график потребления электроэнергии, с помощью нажатия клавиши “Отобразить”. В появившемся окне слева отображается таблица прогноза потребления, справа график потребления.

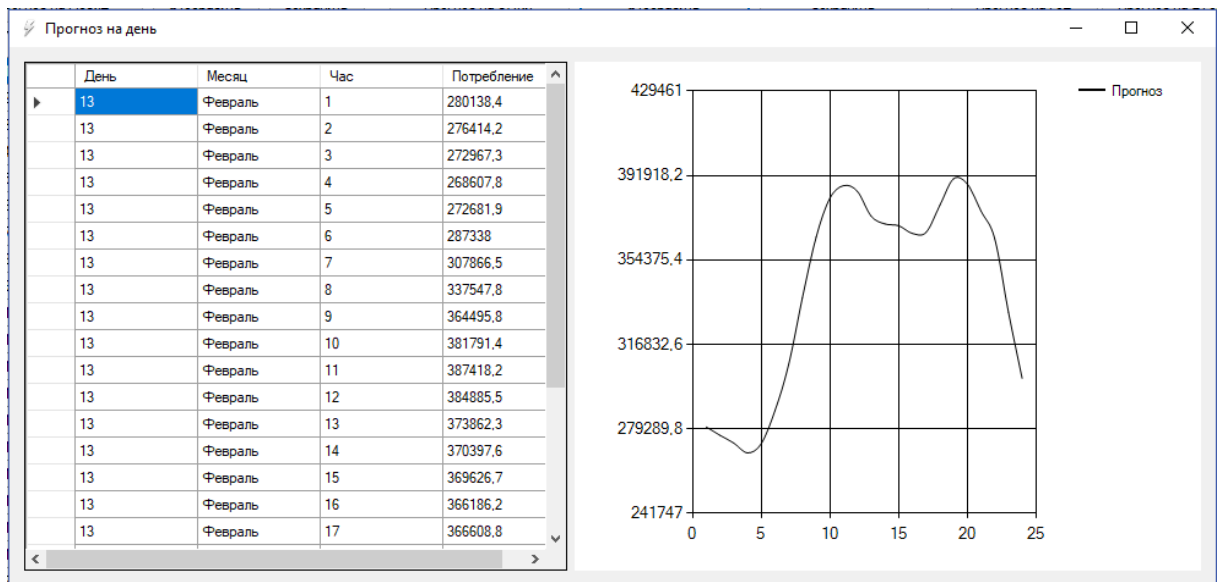


Рис.П2.9. Окно прогноза на сутки

Клавиша “Прогноз на год” – служит для запуска прогнозирования на год вперед. При нажатии данной клавиши будет открыто меню выбора данных для прогнозирования. Данные потребления хранятся в формате .xls. Формат данных должен соответствовать формату данных для обучения данного типа прогнозирования. Для прогноза на год вперед требуется посуточные данные объемом не менее 742 суток. Для прогноза на год возможно использовать почасовые данные, но данных будет требоваться не менее 17808 значений.

Данный прогноз можно проводить если в третьем окне указано что нейронная сеть загружена, если в данном окне отображено что нейронная сеть отсутствует, требуется вернуться в меню обучения и дообучить необходимую сеть.

Результаты прогнозирования в краткой форме(помесячно) представляются в таблице, где показано в первом столбце месяц, во втором потреблении в данном месяце.

	Месяц	Потребление
▶	Октябрь	232374656
	Ноябрь	244341952
	Декабрь	264106736
	Январь	257507568
	Февраль	231678784
	Март	241134624
	Апрель	222287792
	Май	205196000
	Июнь	190952480
	Июль	193459616
	Август	203002768
	На год	2691243264

Рис.П2.10. Таблица прогноза на год

В последней строке указывается сумма прогноза потребления за 365 дней.

После произведения прогноза для графического отображения прогноза можно построить график потребления электроэнергии, с помощью нажатия клавиши “Отобразить”. В появившемся окне слева отображается таблица прогноза потребления, справа график потребления.




Рис.П2.11. Окно прогноза на год

Более подробно с результатами прогнозирования можно ознакомиться при нажатии на клавишу “Отобразить посуточно”. Будет отображена посуточная таблица на 371 сутки справа и график прогноза слева. В таблице при смене каждого месяца будет отображено потребление за месяц, в конце таблицы будет сумма потребления за 365 суток.

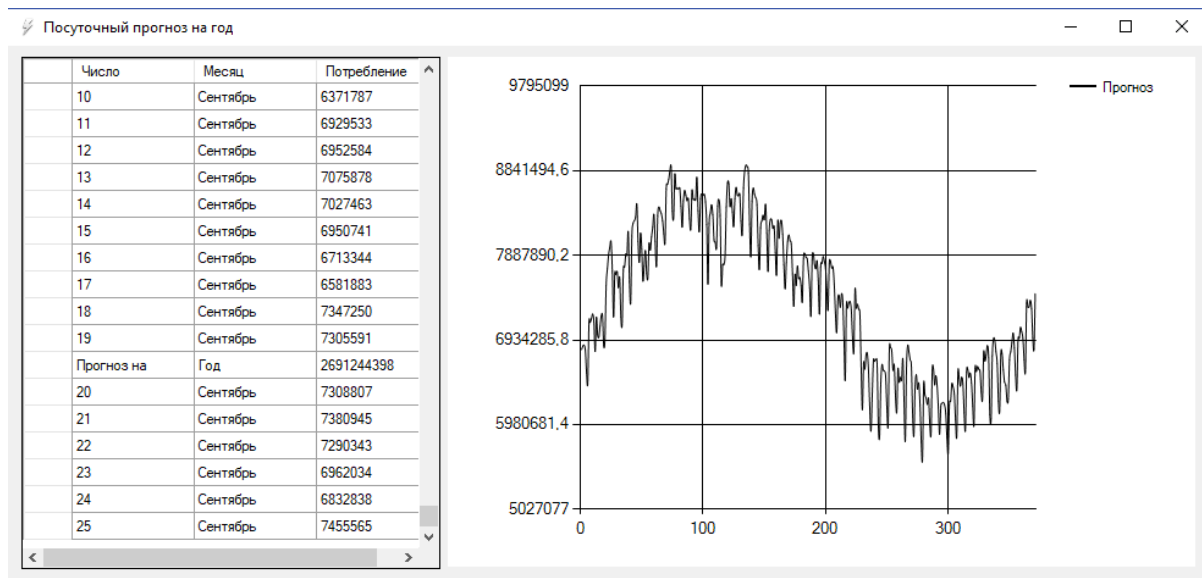


Рис.П2.12. Посуточное потребление на год

В случае необходимости, данный прогноз посуточно можно экспортировать в MS Excel, нажав клавишу “Сохранить”. В этом случае в MS Excel будет сохранён прогноз на 371 день.

ПРИЛОЖЕНИЕ 3

Практическая апробация и акты внедрения



РОССЕТИ



МРСК ЦЕНТРА

Публичное акционерное общество
«Межрегиональная распределительная
сетевая компания Центра»

УДОСТОВЕРЕНИЕ
на рационализаторское предложение

№ 2016-10-004

«20» октября 2016 г.

В соответствии с Положением о рационализаторской деятельности, утвержденным приказом от «30» декабря 2015 г. № 475-ЦА, настоящее удостоверение выдано

**ГНАТЮКУ БОРИСЛАВУ АЛЕКСЕЕВИЧУ,
МОЗОХИНУ АНДРЕЮ ЕВГЕНЬЕВИЧУ,
ОЛОНИЧЕВУ ВАСИЛИЮ ВАДИМОВИЧУ,
СТАРОВЕРОВУ БОРИСУ АЛЕКСАНДРОВИЧУ,
ШИБАЕВУ АНАТОЛИЮ АНДРЕЕВИЧУ**

на предложение, признанное рационализаторским и принятое ПАО «МРСК Центра» к использованию под наименованием: ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ.

Первый заместитель
генерального директора
главный инженер





подпись/ М.П.

Пилюгин А.В.

«22» декабря 2016 г.

Соискатель Староверов Б.А. переименован в Гнатюк Борислав Алексеевич и стал Староверовым Бориславом Алексеевичем (Свидетельство о переименовании И-ФО № 506174 от 17.09.2017 г.).



GENERATION S
2016

СЕРТИФИКАТ

Борислав Гнатюк

«СмартЭнергоПрогноз»

Является выпускником корпоративного акселератора в области энергетики Power&Energy GenerationS 2016/2017

Заместитель генерального
директора - директор по развитию,
член правления АО «РВК»
Г.З. Биккулова

Начальник отдела управления
бизнес-процессами и стандартизации
ОАО "ИЭСК"
Р.В. Русанов

Директор ООО «Лерионтов -
инновации», оператор трека
Л.Ю. Чернигов



Power&Energy

Организатор



Глобальный
партнер



Партнер
по развитию



Инвестиционный
партнер



Оператор трека



Официальный
Telecom партнер



Партнеры номинаций



Индустриальный партнер





GENERATION S
2016

СЕРТИФИКАТ

подтверждает, что

*Информационно-аналитическое обеспечение
прогнозирования в отраслях РСК*

по результатам программы Bootcamp федерального
акселератора GenerationS-2016 приглашен в корпоративный
акселератор трека Power&Energy

Заместитель генерального
директора – директор по развитию,
член правления АО «РВК»


Г.З. Биккулова



Организатор



Глобальный
партнер



Партнер
по развитию



Инвестиционный
партнер



Официальный
Telecom партнер



Партнеры номинаций



Партнер Bootcamp



Оператор трека



Индустриальный партнер





XVIII МЕЖДУНАРОДНАЯ КОНФЕРЕНЦИЯ
НЕЙРОИНФОРМАТИКА-2016

ДИПЛОМ

Третье место
награждается

Гнатюк Борислав Алексеевич
за работу

*Формирование ансамбля нейронных сетей как
основы инвариантной системы прогнозирования
(на примере электропотребления)*

Проректор НИЯУ МИФИ

Председатель программного комитета
конференции "Нейроинформатика-2016"



В.В. Ужва

В.В. Крыжановский

Москва
25-29 апреля 2016



Филиал Публичного акционерного общества
«Межрегиональная распределительная сетевая
компания Центра» - «Костромаэнерго»

АКТ
о внедрении рационализаторского предложения

Регистрационный номер № 2016-10-004 от 20.11.16

Наименование рационализаторского предложения:

Применение нейронных сетей для прогнозирования энергопотребления

Использовано с " 01 " июня 2017 г. в отделе прогнозирования балансов электроэнергии, мощности и анализа потерь Управления реализации услуг филиала ПАО «МРСК Центра» - «Костромаэнерго» в соответствии с описанием рационализаторского предложения.

Заключение:

С 01.06.2017 по 01.12.2017 года в филиале ПАО «МРСК Центра» - «Костромаэнерго» в отделе прогнозирования балансов электроэнергии, мощности и анализа потерь было осуществлено пилотное применение рационализаторского предложения № 2016-10-004 «Применение нейронных сетей для прогнозирования энергопотребления». Считаю целесообразным использование программного модуля для прогнозирования энергопотребления с целью автоматизации формирования сводного прогнозного баланса производства и потребления электрической энергии (мощности), а также тарифно-балансного решения.

Руководитель подразделения:

Заместитель директора по реализации
и развитию услуг



Никоноров А.А.

**Ответственный за использование
рационализаторского предложения:**

Начальник службы эксплуатации СДТУиИТ

Шибяев А.А.

**Ответственный за
рационализаторскую работу:**

Начальник Управления технологического
развития

Соловьев М.А.

« 01 » декабря 2017 г.

С началом использования рационализаторского предложения № 2016-10-004 от 20.10.2016
ознакомлены:

Авторы

Начальник СДТУиИТ КиТ АСУ

Шибяев А.А.

Ведущий инженер отдела эксплуатации АСДУ

Мозохин А.Е.

Зав. каф. АМТ ФГБОУ ВО «КГУ»

Староверов Б.А.

Доцент кафедры АМТ ФГБОУ ВО «КГУ»

Олоничев В.В.


Аспирант каф. АМТ ФГБОУ ВО «КГУ»

Гнаток Б.А.



121205, г. Москва, территория инновационного центра «Сколково»
 Большой бульвар, д.42, строение 1, этаж 1, пом. 839
 ОГРН: 1187746788019
 Тел: +7 (495) 175-41-82
 e-mail: info@stark.su
 Официальный сайт: <http://www.stark.su>

УТВЕРЖДАЮ
 Генеральный директор
 ООО «Старк»


 Пивоваров Константин Львович
 12 ноября 2020 г.



АКТ

о внедрении результатов диссертационной работы Староверова Борислава Алексеевича, посвящённой теоретическому обоснованию и практической реализации системы прогнозирования электропотребления на основе ансамблей нейронных сетей

Материалы кандидатской диссертации, а именно, системы краткосрочного, среднесрочного и долгосрочного прогнозирования электропотребления с помощью ансамблей нейронных сетей, реализованные в виде специализированного программного обеспечения, разработанные Староверовым Б.А., внедрены в производственный процесс и используются для определения загрузки сетей, выявления отклонений потребления и расчета тарифов.

Полученные результаты погрешностей прогнозирования находятся в допустимых пределах, что позволило реализовать модули информационно-аналитической системы, отвечающие за планирование нагрузки распределительных электросетей и расчет тарифов по передаче электроэнергии.

Заместитель генерального директора

 Сиваков И.И.



Публичное акционерное общество «Россети Центр»

Филиал ПАО «Россети Центр» - «Костромаэнерго»

09.08.2021

г. Кострома

АКТ

использования результатов диссертационной работы
на соискание ученой степени кандидата технических наук
Староверова Борислава Алексеевича

Данный акт составлен в том, что результаты диссертационной работы Староверова Борислава Алексеевича, прошли производственную апробацию по получению краткосрочных, среднесрочных и годовых прогнозов потребления электроэнергии.

Испытания показали, что разработанные методы и средства прогнозирования на основе ансамблей нейронных сетей обеспечивают получение почасовых суточных прогнозов со относительным средним отклонением СО не более 1,7%, для среднесрочных прогнозов на неделю вперед - СО = 1,9%, для прогнозов на месяц вперед – СО = 1,85%, для долгосрочного (годового) прогнозирования – менее одного процента.

Система прогнозирования потребления энергопотребления принята к использования в отдел прогнозирования балансов электроэнергии, мощности и анализа потерь филиала ПАО «Россети Центр» - «Костромаэнерго» с целью автоматизации формирования сводного прогнозного баланса производства и потребления электрической энергии (мощности), а также тарифно-балансного решения (Акт о внедрении рационализаторского предложения № 2016-10-004 от 20.11.16 «Применение нейронных сетей для прогнозирования энергопотребления»).

Начальник управления технологического
развития и цифровизации филиала
ПАО «Россети Центр» - «Костромаэнерго»



М.А. Соловьев

Исп.
Соловьев М.А.
8 (4942) 396-352

«Утверждаю»
Ректор Костромского
государственного
университета



Р.А. Наумов

21.01.21

Акт

об использовании разработок по созданию и исследованию системы прогнозирования электропотребления на основе ансамбля искусственных нейронных сетей в учебном процессе

Результаты научных и практических исследований по созданию системы прогнозирования электропотребления на основе ансамбля искусственных нейронных сетей в учебном процессе, выполненных Староверовым Бориславом Алексеевичем, используются для чтения лекций и проведения практических занятий для специальности 270404 – Управления в технических системах (подготовка магистров) по дисциплинам:

«Искусственные нейронные сети и их программная реализация»;

«Интеллектуальные нейросетевые системы управления»,

а также в курсовых и выпускных квалификационных работах, посвященных методам прогнозирования и упреждающего управления.

Для обеспечения учебных занятий подготовлено методическое пособие по лабораторной работе:

«Прогнозирование временных рядов с помощью нейронных сетей».

Директор института
Автоматизированных систем
и технологий КГУ



Ю.Л. Лустгартен

RCM
СИСТЕМЫ

121069, г. Москва, Новинский бульвар д.18 стр. 1
помещение VIII
Тел: +7 499 703-22-48
e-mail: contact@rcm-systems.ru
http://www.rcm.systems

УТВЕРЖДАЮ
Генеральный директор
ООО «RCM-системы»
Темченко Сергей Викторович
06 февраля 2023 г.

АКТ

внедрения результатов диссертационной работы на соискание ученой степени кандидата технических наук Староверова Борислава Алексеевича, на тему: «Теоретическое обоснование и практическая реализация системы прогнозирования электропотребления на основе ансамблей нейронных сетей»

Системы краткосрочного, среднесрочного и долгосрочного прогнозирования электропотребления с помощью ансамблей нейронных сетей, реализованные в виде специализированного программного обеспечения, разработанного Староверовым Б.А., внедрены в производственный процесс и используется для определения режимов загрузки сетей и расчета тарифов.

Результаты эксплуатации показали, что средняя ошибка прогнозирования (СО)

$$\varepsilon_{\text{ср}} = \frac{1}{n} \sum_{i=1}^n \frac{|P_{\text{пр}} - P_{\text{ф}}|}{P_{\text{ф}}} 100\%,$$

n – число прогнозов, $P_{\text{пр}}$ – прогнозная величина $P_{\text{ф}}$ – величина фактического потребления электроэнергии

для почасового прогнозирования на сутки вперед:

- с помощью двухуровневого ансамбля искусственных нейронных сетей СО составляет не более 1,75%, количество прогнозов, распределенных в интервале 0-3% составило 80%;

- с помощью трехуровневого ансамбля искусственных СО уменьшилось до 1,6%, количество прогнозов, распределенных в интервале 0-3% составило 86%.

Для помесечного прогнозирования на год вперед помощью двухуровневого ансамбля искусственных нейронных средняя ошибка находится в диапазоне от 0,6% до 2,5%, общая СО=1,7%.

Для прогнозирования годового потребления электроэнергии с помощью усреднения дневных прогнозов СО = 0,4%.

Полученные результаты погрешностей прогнозирования находятся в допустимых пределах для использования при планировании нагрузки распределительных электросетей и для расчета тарифов по передаче электроэнергии.

Главный разработчик



Цындурев Э.Г.



СЕРТИФИКАТ

УЧАСТНИКА КОНФЕРЕНЦИИ

Староверов Б. А.

Аналитическое обоснование эффективности системы прогнозирования электропотребления на основе ансамбля нейронных сетей

Ректор



Д. П. Маевский