

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное
образовательное учреждение высшего образования
«Южный федеральный университет»

На правах рукописи



Качелаев Олег Вадимович

РАЗРАБОТКА МЕТОДА ПРОГНОЗИРОВАНИЯ И УПРАВЛЕНИЯ
КОМПЛЕКСНЫМИ ЭНЕРГЕТИЧЕСКИМИ СЕТЯМИ НА ОСНОВЕ
ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДАННЫХ

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

Диссертация на соискание ученой степени кандидата технических наук

Научный руководитель:
кандидат технических наук, доцент
Полуянович Николай Константинович

Таганрог – 2026

Оглавление

Список сокращений.....	5
ВВЕДЕНИЕ	6
Глава 1. АНАЛИЗ ВЛИЯНИЯ ОБРАБОТКИ ДАННЫХ НА ТОЧНОСТЬ ПРОГНОЗИРОВАНИЯ НЕЙРОСЕТИ.....	15
1.1 Анализ моделей искусственного интеллекта и методов обработки данных	16
1.2 Теоретический анализ электропотребления.....	21
1.2.1 Влияние характера электропотребителя на точность прогнозирования ...	23
1.2.2 Анализ профилей потребителей	30
1.3 Оценка влияния шума и аномалий на качество обучения нейросети	42
1.3.1 Методы предварительной обработки данных и обнаружения аномалий ..	46
1.3.2 Удаление шума в динамических данных по методу скользящего среднего	48
1.3.3 Применение метода кластерного анализа в задаче обнаружения аномалий.....	49
1.4. Разработка программного модуль обработки и идентификации аномалий во входных данных.....	54
Выводы по главе 1	58
Глава 2. РАЗРАБОТКА МЕТОДА И АЛГОРИТМА НЕЙРОСЕТЕВОГО ПРОГНОЗИРОВАНИЯ В ЗАДАЧАХ ОПТИМИЗАЦИИ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ.....	59
2.1 Робастное обучение нейронных сетей в задачах прогнозирования.....	60
2.2. Модификация метода прогнозирования электропотребления на основе нейросетевой модели для аддитивного потребителя.....	68
2.3 Выбор метрики при обучении нейронной сети.....	71
2.4 Структурная оптимизация нейросети	74
2.4.1 Оценка качества обучения нейросети от ее структуры.....	75
2.4.2 Оценка точности прогнозирования электропотребления от размера скользящего окна.....	80
Выводы по главе 2	83

Глава 3. НЕЙРОЭВОЛЮЦИОННЫЙ МЕТОД ДЛЯ РЕШЕНИЯ ЗАДАЧИ СИНТЕЗА АРХИТЕКТУРЫ НЕЙРОННОЙ СЕТИ.....	86
3.1 Обзор нейроэволюционных методов проектирования архитектуры.....	87
3.1.1 Постановка задачи разработки алгоритма синтеза структуры нейросетевой модели	88
3.2 Описание этапов генетического алгоритма настройки искусственной нейронной сети.....	89
3.2.1 Предлагаемое эволюционное проектирования архитектуры нейронной сети.....	91
3.3 Разработка гибридного алгоритма прогнозирования аддитивного потребителя для системы поддержки принятия решений	96
3.3.1 Реализация функций гибридного алгоритма обучения нейросети в Python	96
3.3.2 Анализ и синтез структур нейросетевых моделей с помощью генетического алгоритма.....	102
Выводы по главе 3.....	104
Глава 4. ОЦЕНКА ЭФФЕКТИВНОСТИ НЕЙРОСЕТЕВОЙ МОДЕЛИ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ.....	106
4.1 Оценка точности нейроэволюционного прогнозирования с подбором гиперпараметров вручную для разных типов потребителей.....	107
4.2 Оценка точности прогнозирования при синтезе структуры нейросетей с помощью генетического алгоритма для разных типов потребителей.....	109
4.3 Экспериментальная оценка совокупности методов повышения точности прогнозирования электропотребления.....	110
Выводы по главе 4.....	116
Глава 5. РАЗРАБОТКА МЕТОДОЛОГИИ ПОМОЩИ ПРИНЯТИЯ РЕШЕНИЙ В КОНТУРЕ УПРАВЛЕНИЯ SCADA	118
5.1. Упреждающее управление в энергосистемах	119
5.1.1 Методы упреждающего управления	121

5.2. Управление энергосетью с применением нейросетевых моделей и систем поддержки принятия решений.....	127
5.2.1 Структура и алгоритм работы нейрокомпьютерной системы.....	127
5.3. Разработка структуры системы поддержки принятия решений	128
5.3.1. Функциональные требования к системам поддержки принятия решений в энергосетях.....	129
5.3.2. Реально-прогнозное управление на основе взаимодействия системы поддержки принятия решений и SCADA-систем	130
5.3.3. Разработка алгоритма работы системы помощи принятия решений	135
5.4. Разработка программного обеспечения системы прогнозирования поддержки принятия решений	140
5.4.1. Схема взаимодействия модулей	140
5.4.2. Реализация алгоритма системы поддержки принятия решений	143
5.5 Оценка экономического эффекта от внедрения разработанной модели	148
Выводы по главе 5	151
Заключение	154
Список используемых источников	158
ПРИЛОЖЕНИЕ А	168
ПРИЛОЖЕНИЕ Б.....	169
ПРИЛОЖЕНИЕ В	170
ПРИЛОЖЕНИЕ Г	181
ПРИЛОЖЕНИЕ Д	184

Список сокращений

АСУ – автоматическая система управления

АСДУ – автоматизированных систем диспетчерского управления

АСТУ – автоматизированных систем технологического управления

БД – база данных

БЗ – база знаний

ГА – генетический алгоритм

КВ – коэффициент вариации

КЗ – коэффициент заполнения

НС – нейронная сеть

ПЭ – потребитель электроэнергии

РЭС – распределительные энергосети

СКО – среднее квадратичное отклонение

СО – скользящее окно

СППР – система поддержки принятия решений

УСПД – устройство сбора и передачи данных

ЭЭ – электроэнергия

ЭП – электропотребление

BatchSize – размер пакета при обучении НС мини-пакетным спуском

LSTM – long short-term memory

NDFLS – Neural network Data Forecast and Logic Support

RNN – recurrent neural network

SCADA – Supervisory Control and Data Acquisition

ВВЕДЕНИЕ

Современная электроэнергетика находится в стадии активной трансформации, связанной с внедрением концепции интеллектуальной энергетической системы (Smart Grid). Что вызывает рост объемов данных, поступающих от датчиков, SCADA-систем (Supervisory Control and Data Acquisition) и приводит к увеличению объемов передаваемой мощности. Возрастают требования к точности обработки поступающей информации и методам обработки информации. Известные методы интеллектуального анализа плохо «работают» с «зашумленными» и неполными данными. В машинном обучении случайные или нерелевантные данные могут привести к непредсказуемым ситуациям, отличным от того, что мы ожидали, что называется шумом. Анализ больших массивов данных в режиме реального времени с учетом фактора неопределенности, работы в условиях неполноты и зашумленности исходной информации являются актуальной задачей.

Особую сложность представляют случаи с аддитивными профилями потребления, которые не демонстрируют цикличности, то есть изменения носят случайный, импульсный характер (например, энергия, расходуемая на единственный технологический процесс, длительный эксперимент или аварийную работу оборудования без периодичности). По предварительным оценкам, составляют около 20–30% от всех потребителей ЭЭ. Для таких сценариев традиционные методы прогнозирования оказываются малоэффективными, что стимулирует разработку новых алгоритмических подходов. Нейросетевое (НС) прогнозирование электропотребления применимо в электроэнергетике и может использоваться в подобных задачах благодаря возможности устанавливать сложные зависимости выходных данных от входных.

Цифровая трансформация энергетики требует принципиально новых подходов к решению трех ключевых задач: – создание эффективных методов и алгоритмов обработки данных, обеспечивающих необходимую скорость вычислений и работу в условиях неопределенности; – разработка точных методов прогнози-

рования, особенно для сложных аддитивных профилей потребления; – совершенствование систем управления энергосетями через внедрение интеллектуальных алгоритмов в SCADA-системы и развитие адаптивных моделей управления, поскольку традиционные SCADA-системы сталкиваются с возрастающими сложностями при обработке информации в реальном времени и принятии решений в условиях неполных или противоречивых данных. Решением становится интеграция систем поддержки принятия решений (СППР), которые осуществляют комплексный анализ текущих параметров сети, исторических тенденций и прогнозных показателей. Такие системы формализуют процесс выбора оптимальных режимов работы, существенно снижая вероятность ошибок оперативного персонала.

В области управления энергосистемами особое внимание уделяется развитию НС-моделей и генетических алгоритмов (ГА). НС показывают высокую эффективность при обработке больших массивов данных и способны адаптироваться к изменяющимся условиям. ГА решают комплекс сложных задач, включая многокритериальную оптимизацию архитектуры НС, где требуется одновременный учет множества параметров: количества слоев и нейронов, типа функций активации и специфики обучающих процессов.

Проблема нейросетевого прогнозирования электропотребления (ЭП) заключается в сложности создания универсальной методики, обеспечивающей минимальную погрешность на разных горизонтах прогнозирования. Основные трудности прогнозирования связаны со сложной нелинейной зависимостью электропотребления от множества недетерминированных факторов, таких как прогноз погоды, плановые и аварийные отключения оборудования. Дополнительную неопределённость вносит изменение графика потребления в зависимости от сезонности и социально-экономических факторов. Существующие методы прогнозирования не обладают инвариантностью к различным условиям потребления: ни одна НС-модель не обеспечивает минимальную погрешность на всём периоде прогнозирования. Кроме того, сложно подобрать оптимальную конфигурацию

сети – слишком простая архитектура плохо обучается, а избыточная увеличивает время обучения без улучшения точности.

Ещё одной проблемой является необходимость обработки больших объёмов данных для обучения и работы НС. При этом отсутствует универсальная метрика оценки точности прогнозов. Также значительное влияние на точность оказывают погодные условия, особенно при использовании прогнозных, а не фактических климатических данных. Важным преимуществом ГА как механизма синтеза структуры НС является их способность к автоматизированному поиску рациональных конфигураций прогнозных моделей для конкретных наборов данных. Они минимизируют влияние человеческого фактора, выявляют скрытые зависимости в исходных данных и повышают устойчивость моделей к различным возмущениям и внешним воздействиям.

Ручное управление в энергосетях становится проблемой в условиях динамично меняющейся нагрузки и сложных аварийных сценариев. Оно не обеспечивает достаточную скорость реакции и не поддерживает предиктивную аналитику. Система помощи принятия решения в энергосетях позволяет перейти от ручного управления к интеллектуальному анализу данных, автоматизированному прогнозированию и оптимальному принятию решений, что повышает надёжность, экономичность и устойчивость энергосистем. Выдачей рекомендаций для диспетчера на основе результатов расчета отклонений фактических значений ЭП от полученных от прогнозной модели. Оператор ориентируется на выводы СППР и учитывает их при принятии решений о заказе электроэнергии на оптовом рынке. Система помогает контролировать адекватность работы НС-модели, например, выявлять аномалии в работе сети (нестандартные профили потребления).

Актуальность работы. В соответствии с программными положениями развития энергетического сектора на период до 2035 года, а также с учетом курса, заданного доктриной энергетической безопасности страны, ключевым направлением модернизации отрасли выступает внедрение цифровых решений и повышение уровня интеллектуализации. В сфере электроэнергетики данная задача реа-

лизуется через формирование концепции интеллектуальной энергетической системы, известной как Smart Grid.. Что вызывает рост объемов данных, поступающих от датчиков, SCADA-систем и приводит к увеличению объемов передаваемой мощности.

Цифровая трансформация энергетики требует принципиально новых подходов к решению трех ключевых задач. Во-первых, это разработка точных методов прогнозирования, особенно для сложных аддитивных профилей потребления. Во-вторых, создание эффективных методов и алгоритмов обработки данных, обеспечивающих необходимую скорость вычислений и работу в условиях неопределенности. В-третьих, совершенствование систем управления энергосетями через внедрение интеллектуальных алгоритмов в SCADA-системы и развитие адаптивных моделей управления, поскольку традиционные SCADA-системы сталкиваются с возрастающими сложностями при обработке информации в реальном времени и принятии решений в условиях неполных или противоречивых данных.

При этом возрастают требования к точности обработки поступающей информации и методам обработки информации. Известные методы интеллектуального анализа плохо «работают» с «зашумленными» и неполными данными в том числе, из-за огромного объема и присущей этим данным разнородности. Анализ больших массивов данных в режиме реального времени с учетом фактора неопределенности, работы в условиях неполноты и зашумленности исходной информации являются актуальной задачей. Особую сложность представляют случаи с аддитивными профилями потребления, которые не демонстрируют цикличности. Для таких сценариев традиционные методы прогнозирования оказываются малоэффективными, что стимулирует разработку новых алгоритмических подходов.

В области управления энергосистемами особое внимание уделяется развитию нейросетевых моделей. Нейронные сети (НС) показывают высокую эффективность в задачах прогнозирования, являющегося фундаментом планирования и контроля. Таким образом становится актуальной задача прогнози-

рования, обеспечивающего соблюдение допустимого отклонения в 5% от заявленных объемов, поскольку превышение этого порога влечет за собой финансовые санкции и оперативные ограничения.

В качестве решения проблемы предлагается разработка прототипа системы поддержки принятия решений, обеспечивающего обработку данных, поступающих от приборов учета, датчиков и метеорологических ресурсов; формирование исходной выборки; контроль работы НС-модели с возможностью автоматического переобучения и/или переобучения; прогнозирование потребления электроэнергии (ЭП); анализ параметров сети, исторических тенденций и прогнозных показателей. Такие системы формализуют процесс выбора оптимальных режимов работы, существенно снижая вероятность ошибок оперативного персонала.

Исходя из этого, актуальность диссертационной работы обусловлена необходимостью создания методов обработки крупных массивов данных и прогнозирования временных рядов с применением нейросетевых подходов, что позволит повысить качество информационной поддержки при принятии управленческих решений, а следовательно — улучшить результативность деятельности энерго-бытовых компаний и укрепить надежность работы распределительных сетей.

Целью диссертационной работы является разработка метода повышения точности краткосрочного прогнозирования электропотребления аддитивных потребителей за счет выявления ключевых факторов, влияющих на функционирование сложной электротехнической системы, внедрения комплекса алгоритмов обработки данных, методов прогнозирования и программного прототипа системы поддержки принятия решений.

Разработанность темы

— задачами обработки больших данных занимались Сивак М.А., Шубат О.М., Ушаков В.Я., Блинов Д.В., Рыженкова К.В., Бибиков В.Д., Качановский Ю.П., Коротков Е.А, J. Wang, X. Chen, и др. в работах основной акцент сделан на технологических аспектах обработки данных, предназначенных для последующего использования в прогнозировании электроэнергии, в том числе в мас-

штабе реального времени. Помимо этого, внимание уделено формальным абстрактным спецификациям, описывающим неитеративные и итеративные подходы, а также обобщающим стратегиям, задействованным при работе с крупными массивами данных. В то же время за пределами указанных исследований остались гибридные решения, объединяющие итеративные и неитеративные методы, и не рассматриваются подходы к оптимизации энергопотребления в процессе обработки данных, поступающих в реальном времени;

– задачами прогнозирования ВР занимались Антонов А.В., Вялкова С.А., Надтока И.И., Билалова А.И., Сивак М.А., Блохин А.В., Серебряков Н.А., Грицай А.С., Р.Н. Хамитов, В.З. Манусов, Ван Эфен, и др. Рассматривались модели машинного и глубокого обучения при прогнозировании потребления электроэнергии, в том числе предлагалось и ансамблевое обучение, использование различных моделей глубокого обучения (LSTM, RNN, МР, и др). В рассмотренных работах не уделяется внимание анализу многомерных временных рядов с учетом внешних факторов (погода, экономика);

– задачами разработки СППР в различных областях занимались Чернова А.Д., Пальчевский Е.В., Гнатюк В.И., Мурыгин А.В, Тынченко В.С., Митрофанов С.В., Колоколов М.В., Юсупова Н.И. и др. Рассматривались задачи разработки и внедрения СППР в различных областях, в том числе и электроэнергетике с целью информационной поддержки принятия управленческих решений. Не во всех работах приводится полное описание комплексного применения наработок по направлениям: – обработка данных; – прогнозирование; – СППР.

Объект исследования – процесс обработки больших данных и прогнозирования временных рядов для организации информационной поддержки принятия управленческих решений на примере электроэнергетики.

Предмет исследования – взаимосвязи между компонентами системы прогнозирования и ППР, математические модели, методы и алгоритмы машинного обучения при прогнозировании и поддержки принятия управленческих решений в сложных электроэнергетических системах.

Научная новизна:

1) Предложен метод обработки больших объемов данных, передаваемых с интеллектуальных счетчиков и датчиков. Метод отличается совокупностью использования метода скользящего среднего для сглаживания небольших выбросов в данных; кластеризации *k-средних* для борьбы со значительными аномалиями. Это позволяет повысить точность и устойчивость прогностических моделей в условиях высокой вариативности и нестационарности данных.

2) Предложен метод прогнозирования ЭП на основе скользящего окна. Метод отличается адаптацией метода пошагового прогнозирования на основе авто-регрессии для задач определения объемов потребления электроэнергии с подобранным на основании экспериментальных исследований размером «окна». Это позволяет повысить точность прогнозирования для потребителей с аддитивным профилем при сохранении относительно небольших размеров НС и простоты структуры.

3) Предложен метод синтеза структуры НС на основе эволюционного алгоритма. Метод отличается тем, что классический генетический алгоритм адаптирован к задаче подбора структурных гиперпараметров НС, модифицирован для повышения скорости работы за счет введения первичного тестирования при обучении модели на небольшом количестве эпох. Это позволяет как сократить время на подбор структуры и обучение НС, так и повысить точность конечного прогнозирования ЭП (на 6-7% процентов).

4) Предложен алгоритм прогнозирования потребления электроэнергии, отличающийся объединением предлагаемых методов обработки информации и прогнозирования. Это позволило добиться точности прогнозирования для аддитивного потребителя более 97%.

5) Предложена система поддержки принятия решений (СППР) как единый программный комплекс для оптимизации управления в сложных электроэнергетических системах. Новизна заключается в объединении в один программный комплекс разработанных методов и алгоритмов: обработки данных; формирования выборки; обучения НС; прогнозирования на необходимый интервал; анализ прогнозных и профильных значений ЭП; визуализация и вывод результатов работы алгоритмов. Это позволит управлять процессом прогнозирования и **повысить** информационной поддержки принятия управленческих решений.

Основные положения, выносимые на защиту:

1) Теоретический и экспериментальный анализ влияния аномалий во входных данных, снимаемых с приборов учета, на эффективность и качество обучения нейронной сети и методы устранения (соответствует п. 4 паспорта специальности 2.3.1).

2) Алгоритм и метод краткосрочного прогнозирования электропотребления, на основе нейронной сети, с генетически оптимизируемой структурой. (соответствует п. 11 паспорта специальности 2.3.1).

3) Метод оптимизации структуры нейросетевой модели на основе генетического алгоритма (соответствует п. 5 паспорта специальности 2.3.1).

4) Методология для решения задачи прогнозирования с помощью СППР на основании установленной взаимосвязей компонентов, включающих разработанные алгоритмы обработки данных, прогнозирования и логических выводов на основе логики ограниченной рациональности. Программный симулятор как совокупность предлагаемых методов и алгоритмов (соответствует п. 12 паспорта специальности 2.3.1).

Достоверность результатов работы базируется на использовании апробированных научных положений и методов исследования и подтверждена экспериментальной проверкой работоспособности предложенных методов и диагностических критериев. Вводимые допущения по нагрузке на вычислительные ресурсы мотивировались проводимыми экспериментами и фактами, известными из практики.

Практическая значимость работы состоит в создании прототипа программного комплекса СППР для обработки данных и прогнозирования объемов электропотребления на основе предлагаемых методов и алгоритмов, что позволит повысить эффективность управления электропотреблением, снизить затраты на энергоресурсы и минимизировать риски перегрузок в энергосистемах и уменьшить роль человеческого фактора при принятии решений в различных ситуациях.

Применение программной реализации разработанных методов позволило:

1) автоматизировано обрабатывать поступающие данные и формировать выборки для НС-модели;

2) создавать прогнозные модели, адаптированные под конкретного потребителя;

3) прогнозировать потребление электроэнергии, обеспечивая точность прогнозов не менее 97%;

4) визуализировать результаты прогнозирования для облегчения интерпретации данных и принятия управленческих решений.

Разработанные решения рекомендованы к внедрению в деятельность энергокомпаний, промышленных предприятий для оптимизации процессов планирования и распределения электроэнергии.

Личный вклад автора. Результаты исследования, представленные в диссертации, получены лично автором под руководством научного руководителя. Из публикаций, подготовленных в соавторстве, в диссертации представлен материал, принадлежащий лично автору.

Соответствие паспорту специальности. Диссертационная работа соответствует паспорту специальности 2.3.1 «Системный анализ, управление и обработка информации, статистика» в следующих областях исследования:

п. 4: Разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта;

п. 5: разработка специального математического и алгоритмического обеспечения систем анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта;

п. 11: методы и алгоритмы прогнозирования и оценки эффективности, качества, надежности функционирования сложных систем управления и их элементов;

п. 12: визуализация, трансформация и анализ информации на основе компьютерных методов обработки информации.

Глава 1. АНАЛИЗ ВЛИЯНИЯ ОБРАБОТКИ ДАННЫХ НА ТОЧНОСТЬ ПРОГНОЗИРОВАНИЯ НЕЙРОСЕТИ

Анализ профиля электропотребления предполагает изучение изменения электрических нагрузок (потребляемой мощности) во времени: в разрезе суток, дней недели и сезонов года. Многофакторный регрессионный анализ позволяет учитывать одновременно несколько факторов, влияющих на энергопотребление (ЭП). Преимуществом этого метода анализа является количественная оценка вклада каждого фактора в изменение объема электропотребления. Он позволяет не только анализировать влияние различных переменных, но и строить прогнозы на основе их ожидаемых значений.

При прогнозировании ЭП используются массивы статистических данных о потреблении активной и реактивной мощности и влияющих факторов (метеорологических, социально-экономических). Используемые методы прогнозирования электрических нагрузок, в частности нейронные сети (НС), некорректно работают с данными, содержащими неопределенности, что приводит к непредсказуемым результатам, отличающимся от ожидаемых.

Причинами зашумления исходных данных являются: – ошибки при сборе данных, такие как неисправность датчиков или человеческий фактор при их вводе; – погрешности измерений, вызванные погрешностью приборов или внешними условиями; – внутренняя изменчивость, возникающая из-за естественных колебаний или непредвиденных событий; – некорректно выполненные операции предварительной обработки (нормализация, преобразование); – неточная маркировка или аннотации данных, что влияет на процесс обучения.

Встает проблема обработки неопределенных (содержащих шумы и аномалии) данных для точного моделирования и прогнозирования ЭП.

Постановка задачи. Для решения проблемы необходимо выполнить следующие задачи:

- разработать метод определения характера профиля потребления электроэнергии;
- разработать методы борьбы с аномалиями (шумы, провалы и др.);

- автоматизировать процесс подготовки выборки для обучения прогностической модели.

С учетом специфики задачи прогнозирования ЭП и ограниченной доступности данных (влияющих факторов) вводятся ограничения на объем и качество исходных данных, поступающих на вход нейросети:

- ограниченный набор влияющих факторов из-за сложности регистрации и формализации таких параметров, как график работы потребителей или техническое обслуживание оборудования и др.;
- ограниченный объем временных рядов данных для прогнозирования – минимум два года почасовых значений;
- отказ от удаления выбросов как этапа предобработки данных, поскольку они могут представлять реальные аномальные события, а не ошибки измерений;
- ограничение количества анализируемых типов аномалий.

1.1 Анализ моделей искусственного интеллекта и методов обработки данных

Нейросетевые модели прогнозирования

Современные информационные технологии, включая искусственный интеллект, обработку больших данных и глубокое машинное обучение, интенсивно развиваются [1]. Для интеллектуализации принятия решений в технических системах применяются искусственные нейронные сети, экспертные системы, нечеткая логика и генетические алгоритмы [2-5]. Ключевой задачей искусственного интеллекта является создание компьютерных систем, способных эффективно решать неформализованные задачи на уровне или выше человеческого. Эти технологии особенно применимы для слабо формализуемых задач [6].

На сегодняшний день известно большое количество как типов и архитектур НС, так и методов их обучения [7]. Хорошо зарекомендовал себя давно известный и распространенный алгоритм обратного распространения ошибки, в особенности для НС типа многослойный персептрон [8]. Также используются другие методы: RProp для "грубого" обучения и алгоритмы оптимизации, использующие нелинейные преобразования градиентов, но не требуют полного пересчета

гессиана (матрицы вторых производных)) для "точного" [9]. Однако эти градиентные методы имеют недостатки, включая трудности с точным расчетом градиента и высокие вычислительные затраты при большой размерности задач [10]. Применение ансамблей нейронных сетей для краткосрочного прогнозирования нагрузки рассмотрено в работах [11-13].

В работе [14] представлены результаты исследований по сокращению электрических нагрузок с использованием интеллектуальной обработки данных. Показаны примеры эффективного снижения расходов на электроэнергию за счет прогнозирования нагрузок и последующего использования прогнозных данных при планировании. Разработанная модель машинного обучения на основе алгоритма CatBoost продемонстрировала точность прогноза более 92%, что подтвердило ее адекватность экспериментальным данным.

Грицай А. С. предложил гибридную модель краткосрочного прогнозирования энергопотребления, основанную на формировании обучающей выборки с функцией конкурентного сходства и трехслойным персептроном [15].

Следует отметить, что существующие методы прогнозирования не всегда способны полностью учесть многорежимность системы, что негативно сказывается на качестве прогнозов [16, 17].

Rahman A и Srikumar V. разработали модель прогнозирования электропотребления зданий на основе глубокой рекуррентной нейронной сети [18]. В исследовании [19] продемонстрирована возможность почасового прогнозирования энергопотребления с использованием рекуррентных нейронных сетей на данных PJM Interconnection LLC. В работе представлены архитектуры RNN и LSTM, параметры которых частично подбирались экспериментально, а частично оптимизировались. Проведен сравнительный анализ влияния оптимизаторов и функций активации на качество моделей.

В работе [20] предложена модель краткосрочного прогнозирования суточных графиков нагрузки Москвы с учетом естественной освещенности, показавшая среднюю абсолютную ошибку менее 2%, что соответствует отраслевым требованиям.

Несмотря на многообразие математических моделей прогнозирования электропотребления, универсального метода не существует [21]. Большинство существующих моделей разрабатывалось для энергосистем или конечных потребителей, таких как здания и промышленные предприятия.

Исследование [21] показывает, что модели почасового прогнозирования для распределительных сетей (РЭС) должны учитывать не только стандартные факторы (время, температура, освещенность), но и дополнительные параметры: отключения в сетях 6–220 кВ, производственный режим потребителей мощностью свыше 670 кВт, наличие централизованного теплоснабжения и инерционность изменения потребления при температурных колебаниях.

Необходимость учета указанных факторов обуславливает выбор нейросетевой архитектуры компактного типа, способной обеспечивать высокую точность прогнозных оценок. В то же время ряд классических подходов к прогнозированию, включая метод опорных векторов и метод главных компонент, базируется на устаревших принципах. Современное решение прикладных задач чаще всего опирается на применение глубоких сверточных и рекуррентных структур НС.

В рамках развития методик прогнозирования электрической нагрузки выделяется направление, связанное с использованием методов машинного обучения. Среди них применяются метод опорных векторов [22], ансамблевые подходы [23], однако наибольшее распространение получили рекуррентные сети [24], что обусловлено их ориентацией на работу с временными рядами.

В работе [25] производится сравнение различных архитектур НС, в задаче прогнозирования ЭП объектов промышленности. Рассматривались модели типа ARIMA и Хольта–Уинтерса, также рассмотрены модели НС типа многослойный персептрон (как классический представитель) и DNN (deep neural network) [25]. Однако в работе [26] приводятся следующие недостатки моделей типа DNN: высокая ресурсозатратность процесса обучения; требование к большому объему обучающей выборки. При этом в [27] указывается недостаток в виде существенных затрат на подбор структуры сети. Дополнительной проблемой выступает чрезмерная специ-

ализация обученной модели: так, она может демонстрировать существенное снижение точности при смене климатической зоны. Аналогично модель, настроенная на данные одних промышленных предприятий, не обеспечивает требуемой точности прогнозов для объекта с особым режимом функционирования или даже для аналогичного предприятия, расположенного в иной стране, вследствие влияния административных факторов.

Нейронные сети, как и генетические алгоритмы перешли из категории перспективных инструментов решения задач в разряд доступных и повсеместно применяемых методов. В работе [28] синтез архитектуры каждой НС осуществляется при помощи генетического алгоритма (ГА). Прогноз осуществляется на час вперед по данным из предыстории, а также по номеру часа, для которого осуществляется прогноз. Причем поступающие на вход системы данные предварительно подвергаются вейвлет-преобразованию для выделения разночастотных компонент временного ряда.

Методы обработки данных

В работе [29] рассматриваются простые методы статистического сглаживания эмпирических данных для устранения шума. Основной подход заключается в замене исходных точек значениями, усредненными по группе соседних точек с использованием скользящего окна. Для этого применяются формулы линейного сглаживания многочленами низких степеней, в частности, по пяти точкам.

К недостаткам данного подхода относятся: высокая чувствительность к погрешностям измерений и аномальным выбросам, вычислительная неудобство формул, а также относительно медленная сходимость к приемлемому результату, который может характеризоваться значительной погрешностью. Отмечается простота программной реализации.

Процедура нормализации входных данных представляет собой их «выравнивание», то есть приведение всех значений к единому стандартному диапазону, например от 0 до 1 [30]. Невыполнение нормализации может привести к тому, что входные данные будут оказывать негативное влияние на активацию нейрона, что, в свою очередь, может стать причиной ошибочных решений сети.

Методам идентификации аномалий в данных электропотребления для НС-прогнозирования посвящено много работ. Например, в работе [31] представлен сравнительный анализ методов, которые используются для выявления аномалий, и обоснован выбор метода на основе нейронных сетей. В работе [32] описан подход на основе нейронной сети, который позволяет учитывать особенности сложных временных рядов электропотребления. В статье [33] представлен алгоритм прогнозирования на основе теории искусственных нейронных сетей, который оптимизирует процесс прогнозирования потребления электроэнергии на промышленном предприятии. В работе [34] представлен подход на основе вариационных рекуррентных автоэнкодеров с вниманием, который позволяет выявлять аномалии в данных временных рядов электропотребления без supervision. В статье [35] представлен подход на основе глубокого обучения для прогнозирования нагрузки в умных сетях, который учитывает особенности сложных временных рядов электропотребления.

Необходимо подчеркнуть, что на текущий момент средства для учета количества и качества электроэнергии достигли высокой степени разработанности [36]. Значительно более сложной выступает задача построения подсистем прогнозирования. Для ее решения разработано множество методик и программных продуктов, ключевое место среди которых занимают искусственные нейронные сети [15, 37]. При этом все они нуждаются в предварительной настройке применительно к конкретным условиям и режимам работы энергетических объектов.

Перечень требуемых классов точности для разных потребителей приведён в постановлении Правительства РФ от 04.05.2012 №442. Для организаций, осуществляющих производственную деятельность, класс точности счётчиков зависит от мощности:

- Для потребителей с максимальной мощностью до 670 кВт для точек присоединения к объектам напряжением 35 кВ и ниже – 1,0 и выше;
- Для потребителей мощностью свыше 670 кВт вне зависимости от требуемого напряжения – класс точности 0,5S и выше.

Вывод. Вывод. В результате анализа методов и моделей, применяемых при обработке больших данных — ввиду их высокой вариативности и значительных информационных объемов — а также при прогнозировании временных рядов в исследуемой предметной области, были выявлены следующие обобщенные ограничения. Среди них — специфичность и узкая направленность, выражающиеся в том, что каждая модель и метод нуждаются в индивидуальной адаптации под конкретного потребителя электроэнергии в задачах прогнозирования временных рядов. Также к числу ограничений относится высокая ресурсоемкость используемых прогнозных моделей. Кроме того, обязательным требованием выступает программная реализация процессов обработки крупных и неоднородных массивов данных, включающих сведения об электропотреблении, поступающие от счетчиков SCADA-систем, и метеорологические данные, получаемые из веб-источников.

Анализируя известные методы обработки данных и модели ИИ выявлено, что существующие на данный момент решения не позволяют эффективно работать с аддитивными профилями потребления в задачах НС-прогнозирования потребления электроэнергии. Встает задача применения методов обработки данных в совокупности с другими методами повышения точности прогнозирования электропотребления нейросетевым способом при ограниченности набора входной информации.

1.2 Теоретический анализ электропотребления

В распределительных электрических сетях профиль потребления электроэнергии важен для обеспечения эффективной и надежной передачи электроэнергии. Профиль нагрузки представляет собой график изменения электрической нагрузки во времени. Профиль нагрузки будет варьироваться в зависимости от типа потребителя (жилые, коммерческие или промышленные помещения), температуры и т.д. Производители электроэнергии используют эту информацию для планирования того, сколько электроэнергии им потребуется для обеспечения в любой момент времени. Для потребителя особый интерес представляет профиль

энергопотребления предприятием за месяц, т.к. на его основании, во-первых, можно построить сравнительный анализ для расчета наиболее оптимального тарифного плана на электроэнергию для предприятия с почасовыми ценами, а во-вторых, в случае перевода расчетов на тарифный план с почасовыми ценами, профиль мощности необходимо будем передавать в адрес энергосбытовой компании на ежемесячной основе.

Гистограммы выступают в качестве инструмента визуализации статистических данных об электропотреблении, предоставляя возможность судить о характере распределения изучаемой случайной величины. Они дают возможность оценить влияние метеорологических факторов, включая температуру, влажность воздуха, атмосферное давление, скорость ветра, осадки и прочие, на характер электропотребления. В качестве иллюстрации на рисунке 1.1 приведены годовые профили потребления для различных категорий потребителей, дополненные линиями тренда, демонстрирующими динамику изменения объемов потребления в разрезе месяцев.

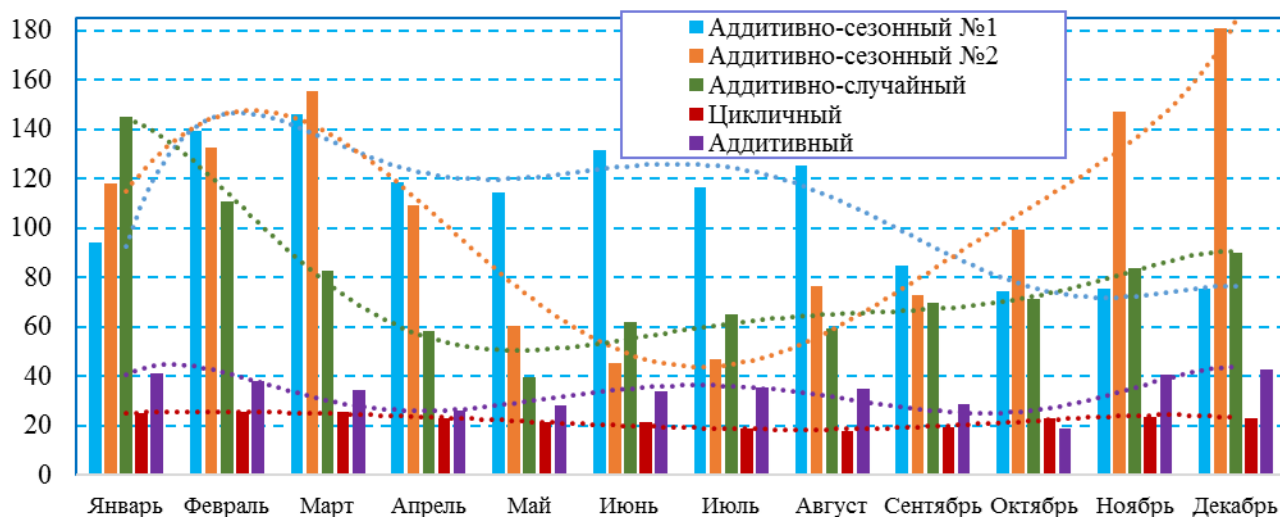


Рисунок 1.1 – Профили электропотребления различных потребителей

На рисунке 1.2 приведены поквартальные профили электропотребления от различных потребителей.




Рисунок 1.2 – Поквартальный профиль электропотребления

Анализ рисунка 1.1 и 1.2 показал, что разделение рассматриваемых потребителей на типы потребления справедливо, поскольку для циклического профиля линия тренда имеет вид близкий к прямой, а для аддитивных профилей потребление от месяца к месяцу значительно отличается.

Производители электроэнергии используют эту информацию для планирования того, сколько электроэнергии им потребуется для обеспечения в любой момент времени. В энергосистеме кривая нагрузки или профиль нагрузки – это диаграмма, иллюстрирующая изменение спроса электрической нагрузки за определенное время. В распределительных электросетях профиль нагрузки при использовании электроэнергии важен для эффективности и надежности передачи электроэнергии.

1.2.1 Влияние характера электропотребителя на точность прогнозирования

Потребление электроэнергии можно разделить на две группы:

- циклический характер (наблюдается повторяемость потребления ЭЭ в зависимости от времени суток, статуса дня (рабочий/выходной) в течении времени (час, день, неделя и т.д.));
- аддитивный характер (не наблюдается повторяемость потребления ЭЭ за периоды времени (час, день, неделя и т.д.)).

Циклический характер электропотребления. На рисунке 1.3 представлен пример повторяющегося потребления ЭЭ. Здесь и далее, потребленная мощность

приводится в относительных единицах (о.е.).

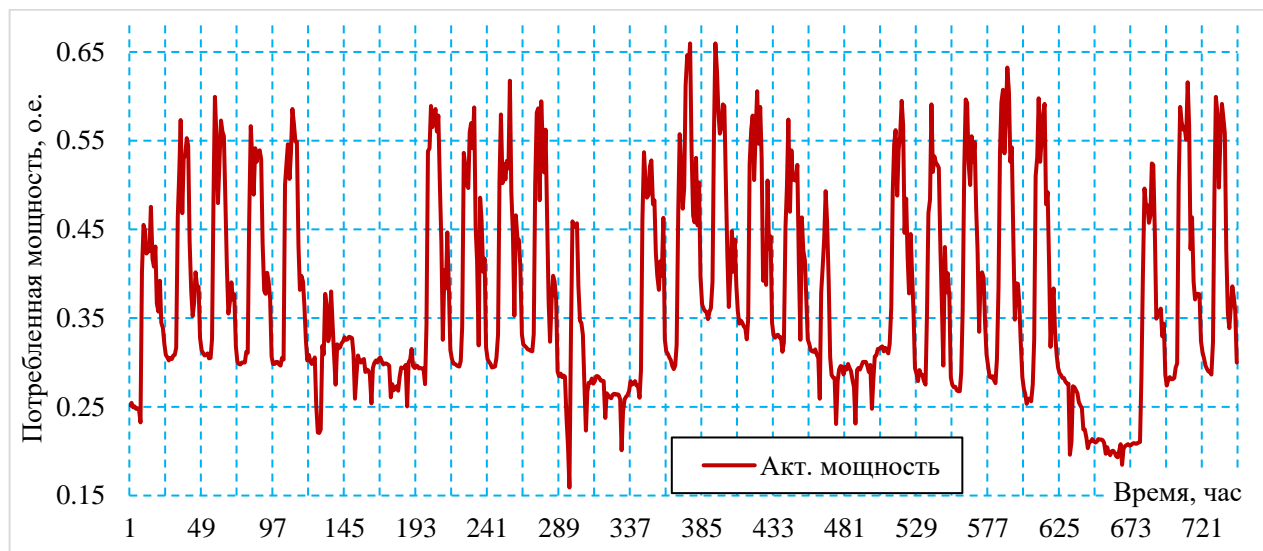


Рисунок 1.3 – Повторяющийся характер электропотребления


Визуально на графике легко отслеживаются будние дни (наибольшее потребление), выходные (наименьшее потребление), а также сокращение потребления электроэнергии в дни перед выходными.

Аддитивный характер электропотребления. Потребление электричества на предприятиях, у которых профиль электропотребления меняется от часа к часу под влиянием совокупности различных факторов, среди которых большинство случайны, представляет – аддитивный характер электропотребления, то есть профиль ЭП не зависит от заранее заданных временных циклов или шаблонов. Ключевой характеристикой такого типа потребления является отсутствие жёсткой цикличности. Потребление является случайным или стохастическим, при этом потребление изменяется дискретно при изменении состояния системы (например, включение или отключение оборудования). Из-за этого задача прогнозирования временного ряда для таких предприятий становится непростой. Традиционные методы статистики или имитационного моделирования неэффективны в условиях неопределенности.

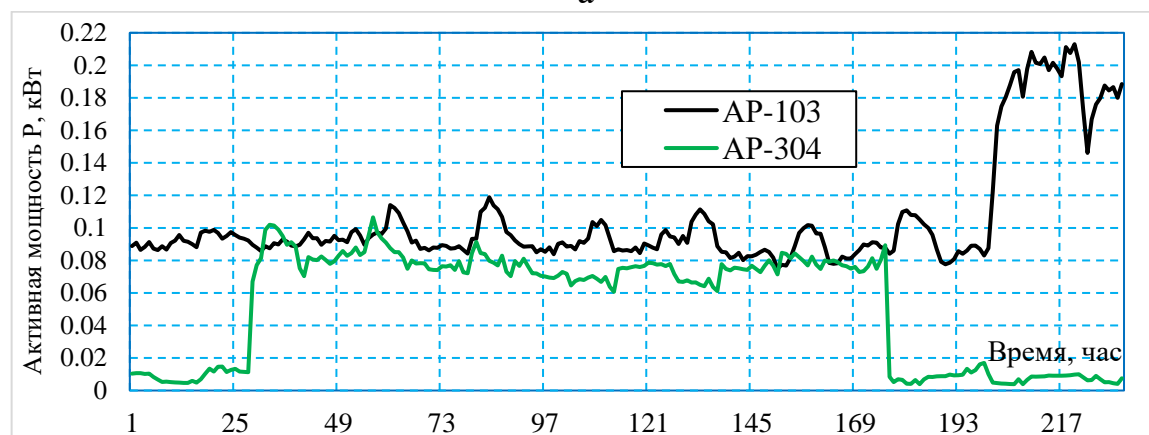
Такие предприятия имеют различные типы потребителей на присоединениях своих распределительных подстанций. Отдельные присоединения демонстри-

руют атипичный режим электропотребления. Подобный характер может периодически воспроизводиться изо дня в день. На примере соответствующих присоединений (рисунок 1.4 а) наглядно видно различие в профилях ЭП. На двух других присоединениях показан характер энергопотребления за 10 дней, (рисунок 1.4 б). Как видно, характер электропотребления носит случайный характер.

Подобный характер электропотребления представляет значительную сложность при прогнозировании по причине необходимости нахождения и учета факторов, оказывающих влияние на ЭП.



а



б

Рисунок 1.4 – Сравнение характера энергопотребления на аддитивных присоединениях AP-103 и AP-304

Таким образом, анализ зависимостей электропотребления на различных присоединениях от времени, выявил, что потребление электроэнергии является атипичным, т.е. не повторяющимся за периоды (час, день, неделя и т.д.) значениями. Эффективные инструменты для работы со слабо формализуемыми или не

формализуемыми задачами – методы искусственного интеллекта и глубокого машинного обучения, которые постоянно развиваются.

На рисунок 1.5 представлен пример атипичного потребления ЭЭ. На приведенном профиле потребления электроэнергии отражено, что характер не повторяется в последующие месяцы.




Рисунок 1.5 – Аддитивный характер потребления

Аддитивно-случайный характер ЭП. Графики фактически потребляемой мощности в соответствии со статусом дня (рабочий/выходной) представлены на рисунке 1.6. На приведенных графиках цвет областей соответствует:

- выходные дни – оранжевый цвет;
- рабочие дни – синий цвет;
- суббота (сокращенный день) – светло синий.




Рисунок 1.6 – График соответствия потребления ЭЭ статусу дней январь 2021

На графике отчетливо видно, что первую неделю месяца потребление ЭЭ было минимальным по причине праздников. Однако, 8 числа (суббота) потребление ЭЭ не соответствовало сокращенному дню, а 16-17 числа потребление электроэнергии было на среднем уровне для данного месяца, т.е. работа не прекращалась, так же, как и в другие выходные дни. Как следствие, прогнозирование электрической нагрузки для такого типа потребителя затруднено отсутствием информации о фактическом графике работы, что является одним важнейших влияющих факторов.

Аддитивно-сезонный характер ЭП. Влияние различных сезонов на затраты ЭЭ для двух разных потребителей приведены на (рисунок 1.7а, б) для различных участков сети, по оси абсцисс отложено время в часах.

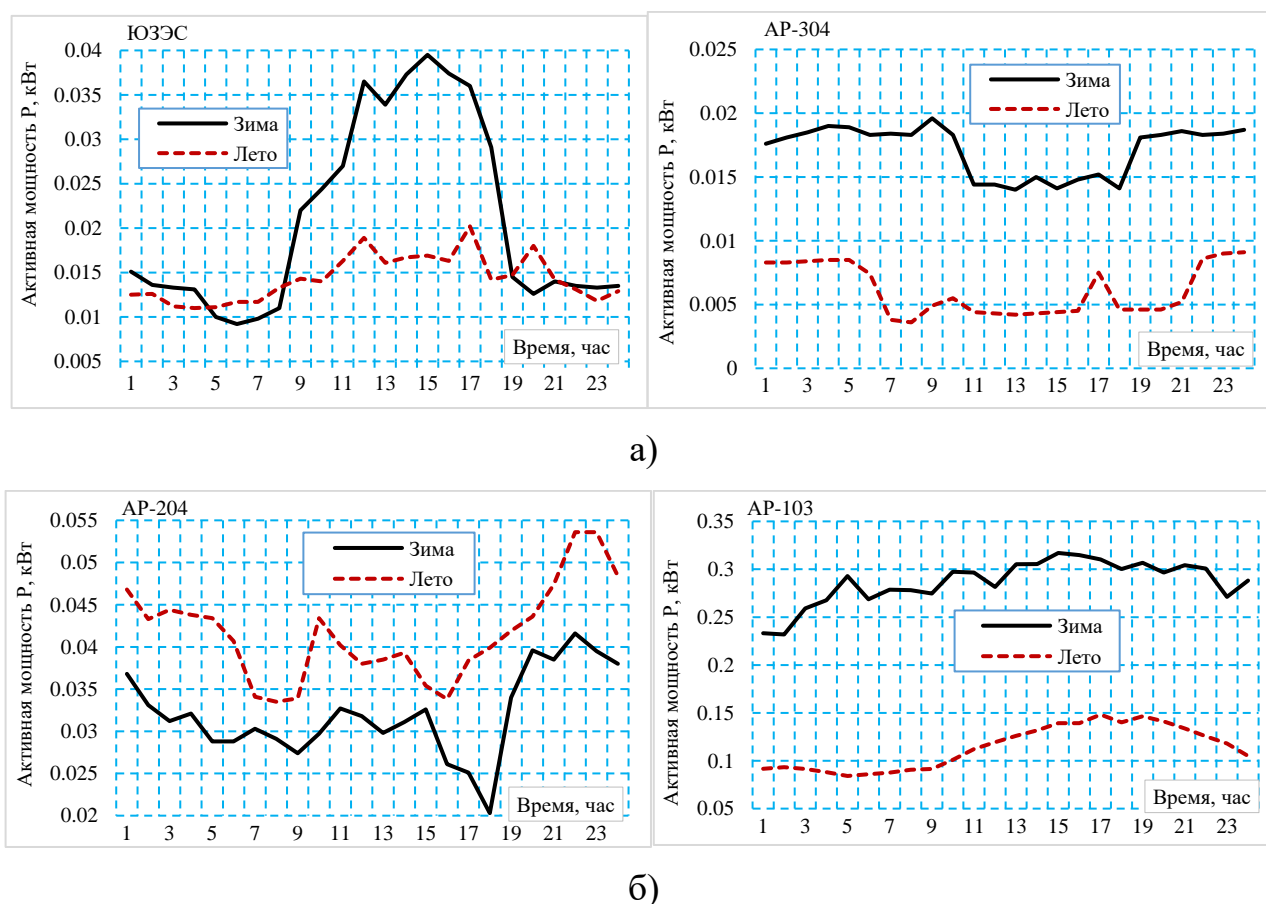


Рисунок 1.7 – Суточные графики нагрузки

а) циклический потребитель; б) аддитивный потребитель

Для оценки того, как характер электропотребителя влияет на точность прогнозирования, требуется сформировать выборку данных, предназначенную для

подачи на вход нейросетевой модели. В рамках рассматриваемого подхода анализируется влияние таких факторов, как сезон (месяц), год, температура, скорость ветра, а также статус дня (рабочий или выходной).

Для численной оценки влияния различных входных факторов на потребление электроэнергии проведен теоретический анализ влияния воздействующих факторов на ЭП, представленный в виде карты корреляции.

Анализ карты корреляции (рисунок 1.8) показал, умеренную отрицательную связь температуры и потребляемой мощности (коэффициент 0,33). Для циклического профиля потребления, ветер имеет слабую положительную корреляцию с параметрами P и Q . Статус имеет умеренную корреляцию с мощностью P и слабую с мощностью Q . Выявлено, что для аддитивных профилей свойственно большое влияние месяца и года, в единичном случае значительное влияние температуры. Влияние остальных параметров незначительное.

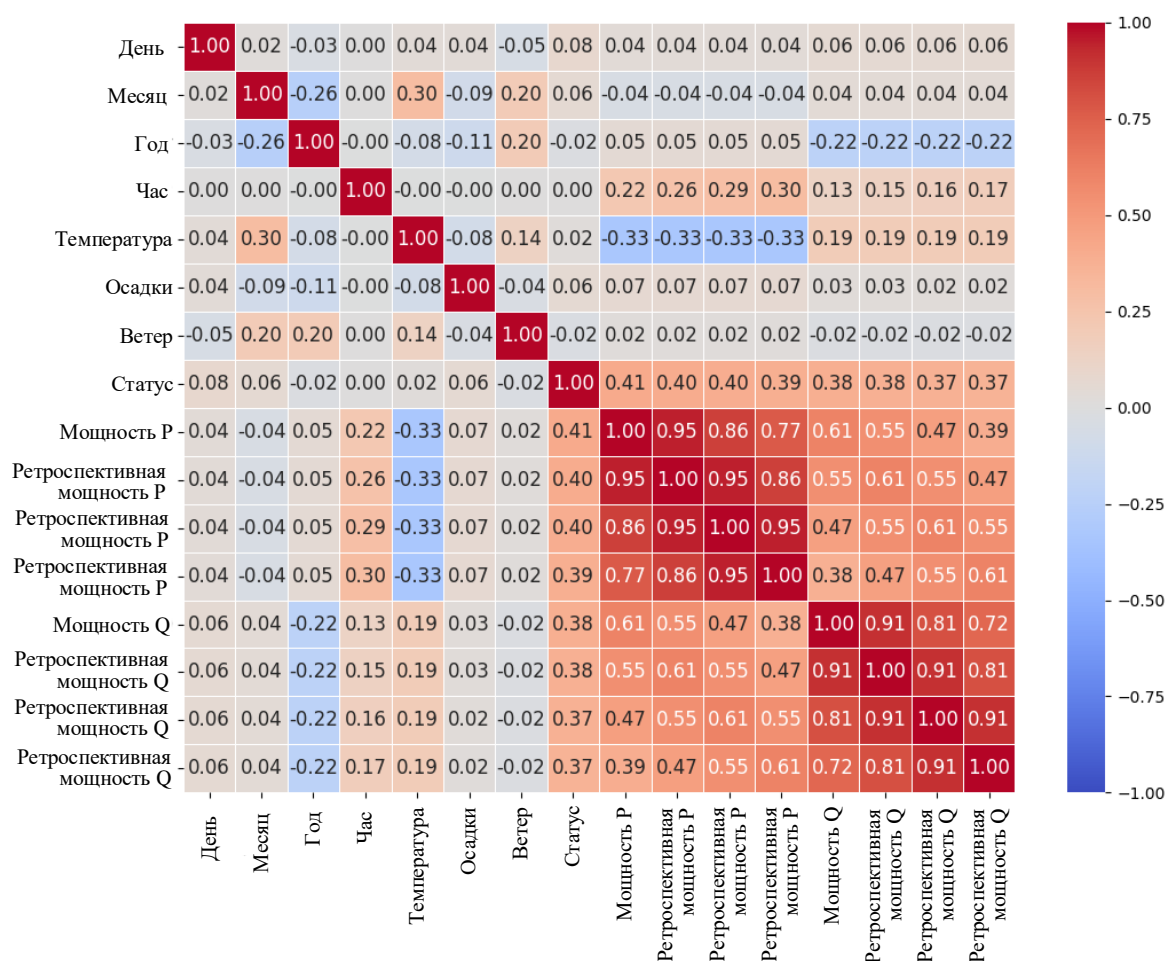


Рисунок 1.8 – Карта корреляции внешних факторов

Выявлено, что для аддитивных профилей свойственно большое влияние месяца и года, в единичном случае значительное влияние температуры. Влияние остальных параметров незначительное.

Определение набора данных для прогнозирования электропотребления. Корректно подобранный набор данных, достаточно описывающий объект исследования влияет на точность прогноза и работу модели.

Подходы к выбору входных параметров модели:

– **Использование прогнозируемого параметра** (величины ЭП) как входного, вместе с меткой времени и набором влияющих параметров (фактические значения ЭП за прошлый период).

– **Применение набора определяющих параметров** как основы для получения прогноза, с дополнительным учётом влияющих параметров (температура, скорость ветра, статус дня, и т.д.).

Исходный набор входных данных для НС может быть записан как (1.1)

$$\{(T_i, W_i, E_i, H_i)\}, i = 1, \dots, n, \quad (1.1)$$

где i – номер суток в выборке; T – вектор календарных признаков (месяц, год, день); W – векторы метеорологических признаков (температура воздуха, наличие осадков, скорость ветра); E – электропотребление, H – социально-экономические (день недели, время).

Для прогнозирования потребления был сформирован набор данных, структура которого показана в таблице 1.1.

Таблица 1.1 – Структура датасета

Название параметра	Тип параметра	Пояснение	Единица измерения
Год	Признак	Год от 2021	–
Месяц	Признак	Номер месяца в году	–
День	Признак	Число месяца	–
Время	Признак	Час суток	ч
День недели	Признак	Рабочий или выходной день	1 / 0
Температура	Признак	Прогноз температуры воздуха	С°
Наличие осадков	Признак	Наличие осадков за сутки (есть/нет)	1 / 0
Скорость ветра	Признак	Средняя скорость ветра за сутки	м/с
Электропотребление	Цель	Электропотребление за сутки	кВт*ч

Результаты сравнения средней абсолютной погрешности НС прогноза в зависимости от характера потребителя электроэнергии сведены в таблицу 1.2.

Таблица 1.2 – Погрешности нейросетевого прогноза электропотребления

Характер потребителя электроэнергии	Погрешность прогноза НС %
Аддитивный	2.52
Циклический	1.71

Проведенный анализ результатов расчета погрешности (таблица 1.2) показал, что:

- от характера изменения данных зависит, то насколько хорошо НС будет составлять прогнозы;
- для данных, которые изменяются по явной закономерности, прогнозы намного точнее, чем для аддитивных данных.

Анализ профилей электропотребления, представленных на рисунках 1.3-1.7, показал наличие в них неопределенностей. Как следует из данных таблицы 1.2, это приводит к значительному снижению точности прогнозирования в случае отказа от использования специализированных подходов.

Следовательно, возникает необходимость в математически обоснованной классификации типа потребителя, исключающей опору на визуальное оценивание. Подобный подход позволяет реализовать способ определения характера профиля электропотребления в виде программного модуля, предназначенного для автоматизации формирования выборки для прогнозной модели.

1.2.2 Анализ профилей потребителей

Анализ профилей потребления электроэнергии подразумевает изучение распределения объема потреблённой энергии по временным периодам и уровням нагрузки. Это позволяет:

- понять характер потребления в целом на объекте на протяжении суток, месяца или года;
- выявлять закономерности в потреблении;
- анализировать структуру энергопотребления и режимы работы.

Как показало исследование, описанное в разделе 1.2.1, временные ряды данных об ЭП содержат неопределенности, что делает сложной задачу классификации профилей ЭП по характерам.

Неопределенность, присущая временным рядам, является фундаментальным аспектом прогнозного моделирования и анализа [38]. Она проистекает из совокупного влияния нескольких ключевых факторов.

Во-первых, существенную роль играет стохастическая природа многих процессов, которая проявляется в виде случайных шумов и флуктуаций, принципиально не поддающихся точному предсказанию. Эти случайные компоненты часто моделируются как белый шум или аналогичные процессы. По характеру непосредственного воздействия, факторы могут быть разделены на две группы. К первой группе относятся факторы, определяющие основную тенденцию динамики (рост или снижение уровней). Вторая группа факторов, вызывающая случайные колебания, отклоняет уровни от тенденции то в одном, то в другом направлении.

Во-вторых, источником неопределенности является неполнота модели, используемой для описания ряда. Любая модель является упрощением реальности и может не учитывать все скрытые зависимости, нелинейности или латентные переменные, что приводит к ошибке спецификации. Даже при правильной спецификации модели возникает неопределенность, связанная с оценкой параметров, поскольку параметры оцениваются по конечной и зашумленной выборке данных, что вносит ошибку выборки.

Одним из ключевых условий сопоставимости уровней динамического ряда выступает единообразие полноты охвата различных составляющих изучаемого явления. Данное требование подразумевает, что уровни ряда за отдельные временные интервалы должны отражать масштаб явления по идентичному составу входящих в него элементов [38].

Неопределенность усугубляется качеством и объемом доступных данных. Сложность отделения сигнала от шума напрямую определяет уровень неопределенности прогнозов [38].

Под неопределенностью применительно к временным рядам электропотребления следует понимать такие фрагменты ряда, в которых изменение объемов потребления вызвано причинами, остающимися неизвестными либо сложными для формализованного учета. Проявлениями такой неопределенности служат непрогнозируемые флуктуации данных, не укладывающиеся в трендовую, сезонную или циклическую составляющие, а также выбросы — значения, выходящие за пределы возможностей исследуемой системы и влияющие на ключевые статистические характеристики ряда.

Визуальная оценка характера потребления. В связи со явной неопределенности характера профиля потребления ЭЭ, будем считать графики подобные этому – аддитивными. Графики профилей потребления ЭЭ для 4-х различных потребителей с наложением линии математического ожидания и СКО от нее приведены на рис. 1.9.




Рисунок 1.9 – Временные ряды потребления (2 недели)

а) аддитивный, б) циклический

Потребителей с ярко выраженной ациклическостью потребления ЭЭ будем считать аддитивными рисунок 1.9 а. Выбросы за пределы зоны СКО носят бессистемный характер, и не поддаются описанию имеющимися в наличии параметрами. На рисунке 1.9 б явно прослеживается интервальность потребления ЭЭ, поэтому их считаем циклическим потребителем. При этом «выбросы» за пределы зоны СКО являются нормальными, что подтверждается анализом гистограмм распределения мощности.

Анализ гистограмм ЭП. Для гистограмм, представленных на рисунке 1.10 а, характерно широкое и сглаженное распределение значений мощности без выраженных пиков, при котором значительная плотность наблюдается на участках, выходящих за пределы среднеквадратического отклонения. Это свидетельствует о сильно изменчивой нагрузке, свойственной аддитивным потребителям. Для циклических потребителей (рисунок 1.10 б), напротив, области наибольшей плотности величин электропотребления располагаются в зоне отклонения. Важно отметить, что наибольшие значения плотности распределения потребленной мощности приходятся на низкое ЭП, что указывает на четко установленный график работы.




Рисунок 1.10 – Распределение значений мощности

а) аддитивный б) циклический

Рассмотрим суточные профили ЭП с аддитивным характером рис. 1.11 а, и циклическим рис. 1.11 б.


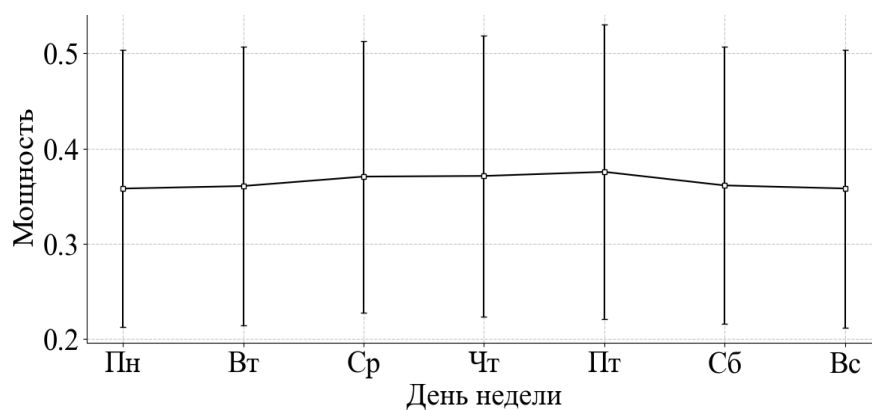


Рисунок 1.11 – Суточный профиль потребления ЭП


а) аддитивный б) циклический

Анализ рис. 1.11 показал, что для циклического потребителя (рисунок 1.11, б) характерен шаблон суточного потребления, при котором с 6 утра начинается повышение ЭП, достигает пика к 8-10 часам, и незначительно уменьшается и держится на уровне до 15-16 часов, затем следует резкое снижение ЭП до минимального. Для аддитивного потребителя (рисунок 1.11, а) отсутствует шаблон суточного потребления (практически прямая).

Проанализировано потребление ЭЭ по дням недели (рисунок 1.12).



а)



б)

Рисунок 1.12 – Потребление по дням ЭП

а) аддитивный б) циклический

Анализ рисунка 1.12 показывает, что для циклических потребителей (рисунок 1.12 б) характерен шаблон потребления для обычной пятидневной недели, при этом у аддитивного потребителя (рисунок 1.12 а) не прослеживается зависимость объемов потребления ЭЭ от дня недели и статуса (рабочий/выходной).

Математическая оценка нестационарности. Методы, позволяющие определить характер потребления ЭЭ работают только для стационарных временных рядов [39] – свойства которых (математическое ожидание и дисперсия) не меняются со временем. Если ряд нестационарный (например, есть тренд или растущая волатильность), то:

- Математическое ожидание, посчитанное для всего ряда, будет бессмысленным. Оно не отражает текущий уровень, так как он изменился с течением времени.

- СКО будет искусственно завышенным, так как оно будет включать в себя не только случайные колебания, но и систематическое изменение уровня.

На рисунке 1.13 приведена одна из выборок и ее линия тренда.




Рисунок 1.13 – Нестационарный профиль потребления

Наличие выраженной линии тренда, в случае рисунка 1.13 идущего на снижение, и при отсутствии явной повторяемости в профиле потребления на всем профиле говорит о нестационарности графика. Однако для корректного подтверждения результатов визуального анализа требуется математическое обоснование.

Для проверки стационарности временных рядов используют различные методы, которые включают графические подходы, статистические тесты и анализ моделей. Стационарность – свойство временного ряда, при котором его статистические характеристики (среднее значение, дисперсия) не меняются со временем. Если данные нестационарны, анализ может быть неточным или вообще не привести к результатам.

Существуют различные методы определения нестационарности:

1) Графический анализ графиков. Может включать поиск трендов, сезонности и изменений в разбросе данных:

- график временного ряда;
- график автокорреляции;
- график частной автокорреляции.

2) Статистические тесты:

- тест Дики – Фуллера;
- тест Квятковского-Филлипса-Шмидта-Шина (KPSS);
- тест Филлипса-Перрона;
- тест Эллиота-Ротенберга-Стока;
- тест Зивота-Эндрюса.

Для борьбы с нестационарностью данных перед анализом применяют различные методы, например дифференцирование, логарифмирование или сглаживание.

Методы оценки стационарности ряда. Для корректного проведения классификации потребителей по характеру ЭП выполняется проверка на нестационарность временных рядов, соответствующих интервалам краткосрочного потребления (до недели включительно). В качестве методов оценки выбраны:

1) Тест Зивота-Эндрюса – модификация метода Дики-Фуллера (ДФ), позволяющая определить единичный корень в присутствии сдвига уровня ряда или сдвига тренда в определенной точке в отличие от изначального метода ДФ. Основан на регрессионной модели, которая тестирует гипотезу о наличии точки разворота тренда в неизвестный момент времени.

Весь временной ряд y_t , где $t = 1, 2, \dots, T$ является индексом времени, может быть смоделирован с помощью линейного тренда без структурных изменений. Альтернативная гипотеза предполагает, что в некоторый неизвестный момент времени τ (где $1 < \tau < T$) происходит изменение параметров тренда. Для каждого кандидата на точку разрыва τ строится расширенная регрессия (1.2):

$$y_t = \beta_0 + \beta_1 t + \gamma_0 D_t(\tau) + \gamma_0 (t D_t(\tau)) + \varepsilon_t, \quad (1.2)$$

где t – переменная времени; $D_t(\tau)$ – это фиктивная переменная, которая равна 0 для всех $t \leq \tau$ и равна 1 для всех $t > \tau$; $t D_t(\tau)$ – переменная взаимодействия между временем и фиктивной переменной; β_1, β_2 – коэффициенты регрессии; γ_0 – параметр, показывающий изменение уровня тренда в момент τ ; ε_t – случайная ошибка модели.

2) Тест KPSS – как позволяющий проверить стационарности относительно детерминированного тренда, работе в дополнении к тестам типа DF и их модификациям, простоте интерпретации. Основан на разложении временного ряда на: детерминистический тренд, случайное блуждание и стационарную ошибку.

Исходный временной ряд y_t для $t = 1, 2, \dots, T$ представляется в виде аддитивной модели (1.3):

$$y_t = \xi t + r_t + \varepsilon_t \quad (1.3)$$

где y_t – это наблюдаемое значение временного ряда в момент времени t ; t – переменная времени, представляющая детерминистический тренд; ξ – коэффициент, определяющий наклон детерминистического тренда; r_t – это ненаблюдаемый компонент случайного блуждания; ε_t – стационарная случайная ошибка с нулевым средним и дисперсией σ_ε^2 .

Статистика KPSS вычисляется по формуле (1.4):

$$KPSS = \frac{1}{T^2} \sum_{t=1}^T \frac{S_{t^2}}{s^2(l)}, \quad (1.4)$$

где T – общее количество наблюдений в ряде; S_t – частичная сумма остатков до момента времени t ; s^2 – состоятельная оценка долгосрочной дисперсии ряда остатков $\hat{\varepsilon}_t$, l – лаг для вычисления дисперсии с учетом возможной автокорреляции, s^2 – стандартная ошибка в форме Ньюи-Уеста.

Проверка на стационарность ряда. Проведена проверка фрагментов временного ряда ЭП для различных потребителей на стационарность. Результаты исследования сведены в таблице 1.3

Таблица 1.3 – Оценка стационарности

Рассматриваемый потребитель	Фрагменты временного ряда				
	Неделя 1	Неделя 2	Неделя 3	Неделя 4	Неделя 5
Потребитель 1	Стац	Стац	Стац	Стац	Стац
Потребитель 2	Стац	Стац	Стац	Стац	Стац
Потребитель 3	Стац	Стац	Стац	Стац	Стац
Потребитель 4	Стац	Стац	Не стац	Стац	Стац
Потребитель 5	Не стац	Стац	Стац	Стац	Стац
Потребитель 6	Стац	Стац	Не стац	Стац	Не стац
Потребитель 7	Стац	Стац	Стац	Не стац	Стац
Потребитель 8	Стац	Стац	Стац	Стац	Стац
Потребитель 9	Стац	Стац	Стац	Стац	Стац

Проведенный анализ показал, что в профилях и циклических и аддитивных потребителей могут находиться нестационарные участки (рис. 1.13, б). Избавляться от нестационарности предлагается логарифмированием (1.4), позволяющим уменьшить влияние больших значений (выбросов):

$$y_t = \ln(x_t + c), \quad (1.5)$$

где x_t – исходное значение в момент времени t ; y_t – преобразованное значение; c – константа (10^{-10}).

Оценка потребителей по коэффициенту вариации. В целях анализа и разделения потребителей по типу электропотребления, исключая необходимость визуального анализа профиля, предлагается применять коэффициент вариации (КВ). Указанный коэффициент является общепринятой характеристикой рассеяния вероятностного распределения, выражается в процентах и рассчитывается как частное от деления среднеквадратического отклонения σ на среднее арифметическое μ .

В рамках выполняемой работы определение характера потребителя выполняется для выбора корректного типа прогнозной модели. По этой причине не стоит задача определения характера участков на профиле потребления ЭЭ.

Коэффициент вариации (1.6) используется для выражения точности и повторяемости анализа и выражает, какой процент от среднего значения составляет разброс данных.

$$CV = \frac{\sigma}{\mu} \cdot 100, \quad (1.6)$$

где: σ – ср. квадратичное отклонение (СКО); μ – математическое ожидание. СКО рассчитывается по формуле (1.7):

$$\sigma = \sqrt{\frac{\sum (S_n - S_{cp})^2}{n-1}}, \quad (1.7)$$

где: S_n – текущее значение, n – длина ряда, S_{cp} – среднее арифметическое значений ряда.

Математическое ожидание временного ряда – это его средний уровень, вокруг которого колеблются значения, то есть среднее арифметическое всех значений ряда (1.8):

$$\mu = \sum_{t=1}^n a_t p_t, \quad (1.8)$$

где a_i – i -ое значение в выборке, p_i – вероятность появления a_i .

Расчет дисперсии производится по формуле (1.9):

$$D = \frac{\sum_i |a_i - \bar{a}|^2}{n}, \quad (1.9)$$

где a_i – i -ое значение в выборке, \bar{a} – выборочное среднее, n – длина ряда.

Расчет коэффициентов вариации. Для адаптации коэффициента вариативности для решения задачи классификации потребителей по характерам экспериментально в ходе работы определены пороговые значения:

- $CV \leq 4.4$ – циклический потребитель;
- $CV > 4.4$ – аддитивный потребитель.

Результаты расчета коэффициента вариации для различных профилей электропотребления обобщены в таблице 1.4.

Как свидетельствуют полученные результаты, возрастание данного показателя у явно выраженного циклического потребителя объясняется резко неравномерным характером работы, при котором кратковременные пики потребления чередуются с длительными этапами практически полного отсутствия нагрузки. Подобная картина свойственна объектам с ярко выраженной циклическостью функционирования – к числу таких относятся офисные и торговые помещения, а также производства, где мощное оборудование включается лишь эпизодически.

Таблица 1.4 – Расчет коэффициентов вариации

Рассматриваемый профиль	Фрагменты временного ряда					K _{CV} , сред
	Неделя 1	Неделя 2	Неделя 3	Неделя 4	Неделя 5	
Потребитель 1	1.367	1.438	1.337	1.454	1.116	1.342
Потребитель 2	0.397	0.415	0.501	0.397	0.501	0.442
Потребитель 3	0.536	0.538	0.581	0.464	0.563	0.536
Потребитель 4	0.443	0.502	0.572	0.718	0.408	0.528
Потребитель 5	0.838	0.971	0.907	0.736	0.381	0.465
Потребитель 6	0.129	0.084	0.198	0.105	0.126	0.128
Потребитель 7	0.124	0.132	0.109	0.123	0.122	0.122
Потребитель 8	0.221	0.173	0.197	0.319	0.3	0.242
Потребитель 9	0.256	0.276	0.262	0.247	0.244	0.257

Причины аномально высокого КВ:

- преобладание «ночного провала» (для жилых и офисных зданий): Высокое потребление днем и почти нулевое ночью приводит к низкому среднему значению (μ) и большому разбросу (σ);
- периодическая работа мощного оборудования (для промышленности): Кратковременные включения мощных станков или двигателей создают резкие пики на фоне низкого базового потребления;
- сезонность и пиковые нагрузки (для всех типов): Работа климатической техники (кондиционеров летом или электроотопления зимой) лишь в периоды экстремальных температур, что создает сильный разброс данных при усреднении за длительный период.

Хотя коэффициент вариации может выступать в качестве приемлемого классификационного инструмента, для выполнения всестороннего анализа его целесообразно использовать совместно с другими подходами. В настоящем исследовании в роли дополнительного средства классификации применяется коэффициент заполнения графика нагрузки (1.10):

$$K_3 = \frac{P_{\text{ср}}}{P_{\text{max}}}. \quad (1.10)$$

Результаты расчета КЗ сведены в таблицу 1.5. Оценивать результаты расчетов следует, исходя из тех же особенностей решаемой задачи, что и при оценке КВ, а именно – чем больше значение коэффициента, тем большая аддитивность данных в рассматриваемом ряду.

Таблица 1.5 – Расчет коэффициента заполнения графика потребления ЭЭ

Рассматриваемый профиль	Фрагменты временного ряда					К _з , сред
	Неделя 1	Неделя 2	Неделя 3	Неделя 4	Неделя 5	
Потребитель 1	0.207	0.234	0.248	0.222	0.200	0.226
Потребитель 2	0.373	0.503	0.505	0.543	0.376	0.461
Потребитель 3	0.397	0.414	0.419	0.440	0.403	0.414
Потребитель 4	0.456	0.419	0.408	0.365	0.528	0.432
Потребитель 5	0.491	0.470	0.461	0.491	0.461	0.473
Потребитель 6	0.606	0.778	0.737	0.558	0.543	0.653
Потребитель 7	0.643	0.568	0.580	0.651	0.628	0.613
Потребитель 8	0.707	0.801	0.689	0.721	0.798	0.749
Потребитель 9	0.797	0.740	0.847	0.798	0.782	0.792

Таким образом анализ таблицы 1.5:

- позволил определить пороговое значение $K_3 \approx 0,55$ как границу для выявления профилей с циклическим характером. При значении $K_3 > 0,55$ считаем потребителя аддитивным;
- подтвердил справедливость выбора КВ как одной из метрик оценки профиля потребления.

Исходя из результатов исследования, рассматриваемые профили ЭП можно разделить на группы:

- циклические (Потребители 1 – 5);
- аддитивные (Потребители 6 – 9).

Таким образом, Проведенный анализ профилей электропотребления показал, что временные ряды данных содержат неопределенности. Вследствие некорректного определения характера профиля происходит ошибочный выбор модели и ее архитектуры, что либо делает невозможным выполнение прогноза, либо приводит к недопустимо низкой его точности. Указанное обстоятельство обуславливает актуальность задачи классификации профилей по характеру электропотребления.

Предложенный метод классификации профилей электропотребления базируется на логарифмической трансформации исходных данных и последующем применении теста Зивота–Эндрюса для обнаружения структурных сдвигов, а также теста KPSS, позволяющего оценить стационарность исследуемого ряда. Данный метод позволяет установить характер исходного профиля потребления электроэнергии.

1.3 Оценка влияния шума и аномалий на качество обучения нейросети

По данным, опубликованным «Транснефтьэнерго» [40], 60% всех отключений у промышленных потребителей связаны с провалами напряжения. Исследования качества электроэнергии [41] показывают, что в 30% случаев показатели на промышленных объектах не соответствуют ГОСТ 32144-2013, в основном по

отклонениям напряжения (18%) и коэффициенту несимметрии по нулевой последовательности (6%).

Нарушения качества электроэнергии в РФ чаще всего вызывают сбои технологического оборудования из-за провалов или прерываний напряжения (52% случаев) и гармоник (18%) [41]. При этом переход на технологии интеллектуальных систем может увеличить ущерб от падений напряжения [42].

На точность прогнозирования электропотребления существенно влияют шумы датчиков тока и напряжения, снижающие достоверность измерений. Основные типы шумов включают:

- Дробовой шум (Шоттки);
- Тепловой шум (Джонсона-Найквиста);
- Фликкер-шум;
- Импульсный шум;
- Лавинный шум.

Причины появления шумов в датчиках. Основными причинами шумов в датчиках являются физическая природа тока (дробовые и тепловые шумы), неидеальность материалов (фликкер-шум), температура, ширина полосы пропускания, электромагнитные помехи, коммутация (импульсные шумы) и высокий уровень напряженности поля (лавинный шум). Количественный вклад шумов в данные об электропотреблении варьируется от менее 0,1% в идеальных условиях до 5-10% и выше в тяжелых. Согласно исследованиям [43, 44], уровни аномалий в реальных данных энергокомпаний обычно составляют 2-5%.

Ориентировочные диапазоны аномалий в данных включают: крупные выбросы (0.1–2% от выборки), провалы (0.5–5%, иногда до 10-15%) и фоновое зашумление с отклонением 0.5–2% от текущего значения. Содержание аномалий различается по типам потребителей: у промышленных – частые провалы и 1–3% выбросов; у жилых – шум 1–2%, крупные аномалии редки; у коммерческих – выраженная цикличность, а погрешность определяется точностью оборудования.

Проведенное исследование выявило значительное влияние аномалий типа «провалов» в данных электропотребления (ЭП) на процесс обучения нейросетевой прогностической модели и итоговую точность прогнозов. Термином «провалы» обозначаются фрагменты временного ряда, где показатели мощности по неизвестным причинам, опускаются до нулевых значений. Этот тип аномалий встречается наиболее часто.

Проведено сравнение фактических данных с прогнозными оценками (рисунок 1.14) в трех сценариях: при использовании исходной (нескорректированной) обучающей выборки, а также при применении выборок, в которые были целенаправленно внесены аномалии, выражающиеся в снижении величин потребленной мощности на случайно выбранных участках на 20% и 70%.

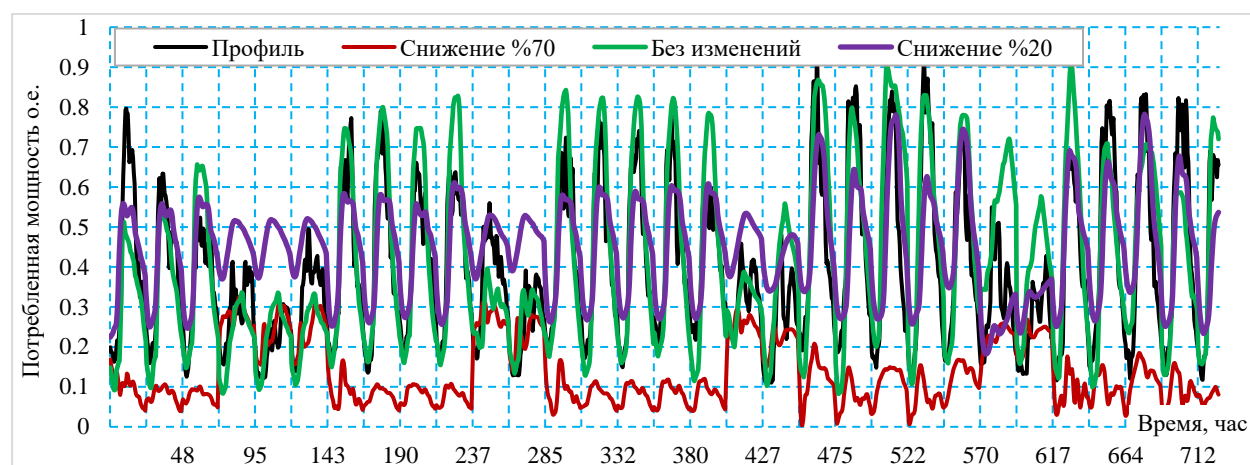


Рисунок 1.14 – Сравнение результатов прогноза при наличии аномалий в данных

В таблице 1.6, приведено сравнение расчета отклонений погрешностей прогнозирования для потребителей с различным профилем ЭП, при наличии и отсутствии аномалий в обучающей выборке. Такие аномалии могут возникать, например, при достижении электропотреблением какого-то порогового значения. Как следствие запускается внешний процесс, в результате которого снижается потребление. Т.е. аномалия вызвана действием энергосистемы по сдерживанию спроса для поддержания стабильности.

Таблица 1.6 – Расчет отклонений

Состояние выборки \ Тип потребителя		Погрешность прогноза %		
		Циклический	Аддитивно – сезонный	Аддитивный
Аномалии в работе потребителя	Снижение 30%	14.09	14.87	33.51
	Снижение 70%	65.6	42.56	52.23
	Без изменений	5.76	2.77	0.88

Анализ погрешностей, представленный в таблице 1.6, продемонстрировал, что наличие указанных снижений объема ЭП на 20% и 70% оказывает существенное негативное воздействие на результат обучения и точность прогнозов. Присутствие подобных аномалий в обучающих данных приводит к ухудшению качества прогноза как минимум на 9%, что является недопустимым значением.

Аномалии этого типа обычно удаляются из данных для обучения модели, так как они искажают реальную картину спроса. Однако, если при наличии их в большом количестве, полностью их удалить, итоговая выборка может значительно потерять в информативности.

На рисунке 1.15 приведен график сравнения результатов прогнозирования электропотребления при наличии пропусков в обучающей выборке и при их замене данными за аналогичный период времени для данных с циклическим профилем потребления.

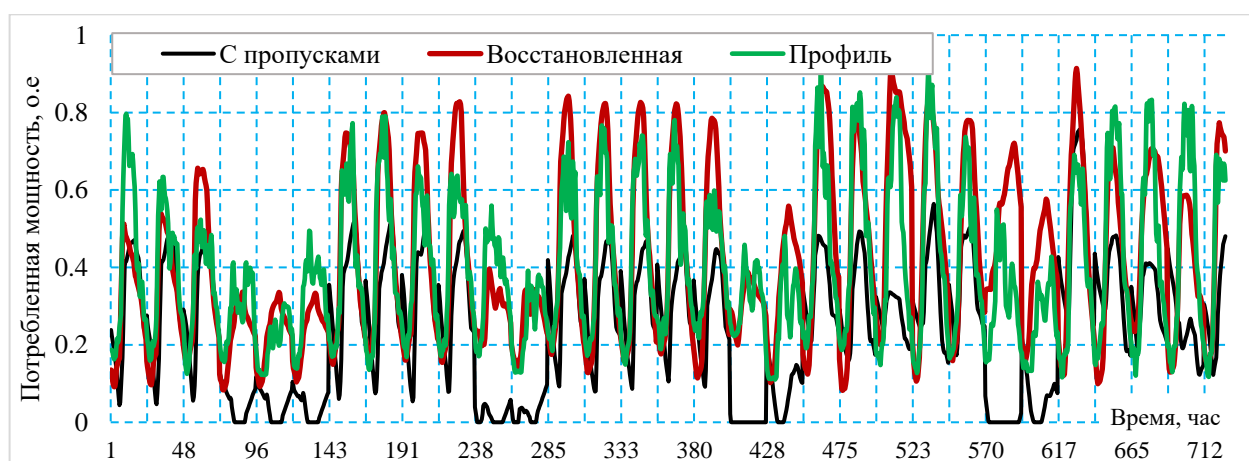


Рисунок 1.15 – Сравнение результатов прогноза при наличии и отсутствии пропусков в данных для циклических данных

В масштабах выборки (2 года, 17520 значений) провалы занимали не более 5%. Результаты расчетов отклонений сведены в таблице 1.7.

Таблица 1.7 – Расчет отклонений

Состояние выборки \ Тип потребителя	Погрешность прогноза %		
	Аддитивный	Циклический	Аддитивно-сезонный
Провалы	44.49	39.12	4.20
Без изменений	0.88	5.77	1.37

Анализ табл. 1.7 показал, что наличие провалов в выборке данных значительно увеличивает погрешность прогнозирования. Это является следствием снижения качества обучения НС-модели. Поскольку ошибка превышает в некоторых случаях значение в 30% можно говорить, что НС не может обучиться корректно на таких данных.

Встает задача в предварительной обработке данных, нацеленной на обнаружение и устранение аномалий и шума для повышения качества обучения НС-модели прогнозирования.

1.3.1 Методы предварительной обработки данных и обнаружения аномалий

Подготовка и обработка данных связана с решением проблемы «аномалий» в исходных данных. Приведены наиболее распространенные варианты «аномалий»:

- По различным причинам могут отсутствовать данные во временном ряду выборки. Причиной «провалов» может служить сбой в работе датчиков или ошибки во время передачи данных от устройства к устройству.

- Могут наблюдаться «снижения» – фрагменты ряда данных ЭП обучающей выборки, в которых значения в силу не учитываемого воздействующего фактора имеют снижение объемов ЭП.

- Наличие дубликатов значений – значений, которые не изменялись на протяжении некоторого количества периодов снятия данных (например, 3-5 часов).

Приведены некоторые из инструментов предобработки: [45]

- Поиск проблемных данных – Возможно проводить в режиме визуальной оценки графика рассматриваемой функции.

- Заполнение пропусков – маркировка пропусков (пропуск становится признаком) и/или заполнение пропусков соответствующими логике значениями

(аналогичный по признакам интервал из имеющегося объема ретроспективных данных).

– Обработка дубликатов записей – Обработать дубликаты нужно, если они возникли в результате технического сбоя, ошибок ввода, или этого требует подход к решению задачи.

К предобработке также относится очистка данных. Очистка данных включает в себя удаление шума и обработку пропущенных значений в наборе данных. Шум в данных может возникать из различных источников, включая экологические факторы и ошибки датчиков.

В задачах обработки информации для НС прогнозирования электропотребления можно использовать кластеризацию, для:

- Выявления аномалий. Обнаружение необычных паттернов потребления, которые могут указывать на неисправности оборудования, утечки или несанкционированное использование.
- Мониторинга оборудования. Кластеризация данных с датчиков промышленного оборудования для выявления неэффективных режимов работы.

Устранить проблему можно при помощи предобработки, которая включает в себя несколько этапов, таких как очистка данных, нормализация и преобразование. Эти этапы необходимы для подготовки исходных данных к обучению модели. На рисунке 1.16 приведен алгоритм обработки данных.

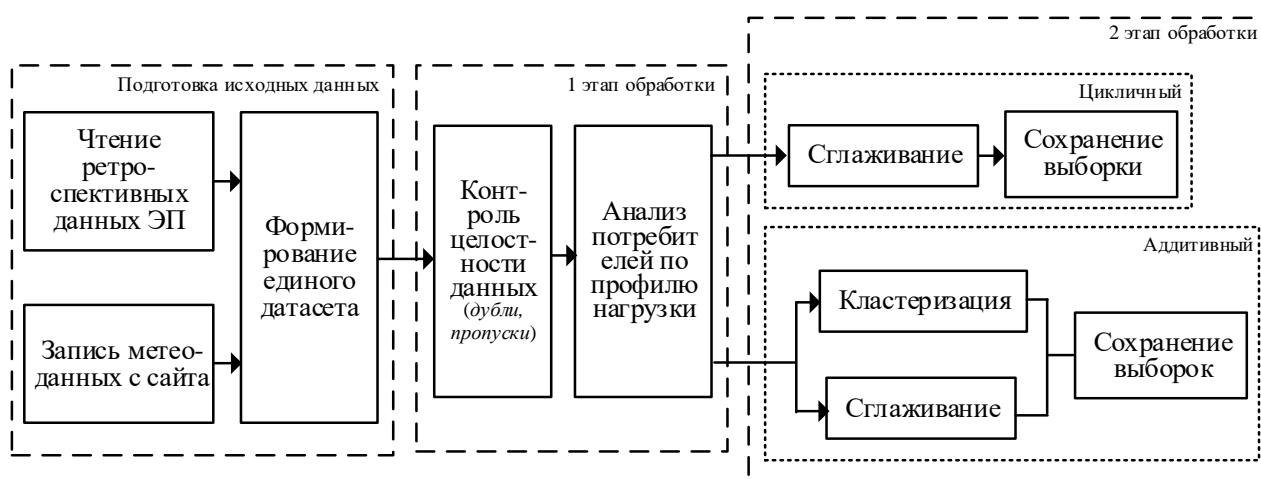


Рисунок 1.16 – Алгоритм обработки данных

Формирование выборки и обработки исходной информации включает в себя 3 этапа (рисунок 1.16):

1) Подготовка исходных данных. Выполняется сбор необходимых данных, их разметка как признаков для выборки и расположение в необходимом порядке.

2) I этап обработки. Выполняется поиск дублей и заполнение пропусков в данных. Производится анализ профиля потребления по характеру.

3) II этап обработки. В зависимости от характера профиля выполняется либо только сглаживание (циклический профиль), либо сглаживание параллельно с кластеризацией (аддитивный профиль). По завершении работы сохраняются готовые выборки в нужном формате.

1.3.2 Удаление шума в динамических данных по методу скользящего среднего

Рассмотрим применение метода скользящего среднего для предобработки данных. Подход реализуется итеративно, с предварительным созданием укрупненных интервалов. В последствии, при формировании следующего интервала, за основу будет браться предыдущий, но со сдвигом на одну позицию. Для каждого такого укрупненного интервала вычисляется среднее значение [46].

Рассмотрим влияние сглаживания данных на точность прогнозирования. Результаты сглаживания данных представлены на рисунке 1.17. в сравнении с фактическими значениями. Размер скользящего среднего подбирался экспериментально. Как наиболее подходящий и универсальный выбран размер «окна» 5.




Рисунок 1.17 – Пример обработанных данных электропотребления для аддитивного профиля

На рисунке 1.18 для сравнения приведены следующие кривые потребления электроэнергии: фактическое ЭП; прогнозное с применением сглаживания;

прогнозное без предварительного сглаживания. В таблицу 1.8 сведены расчетные значения ошибки прогнозирования при различном состоянии выборки перед обучением, а данные о точности прогнозирования при сглаживании входных данных при помощи скользящей медианы и экспоненциального скользящего среднего получены исходя из работы [47].

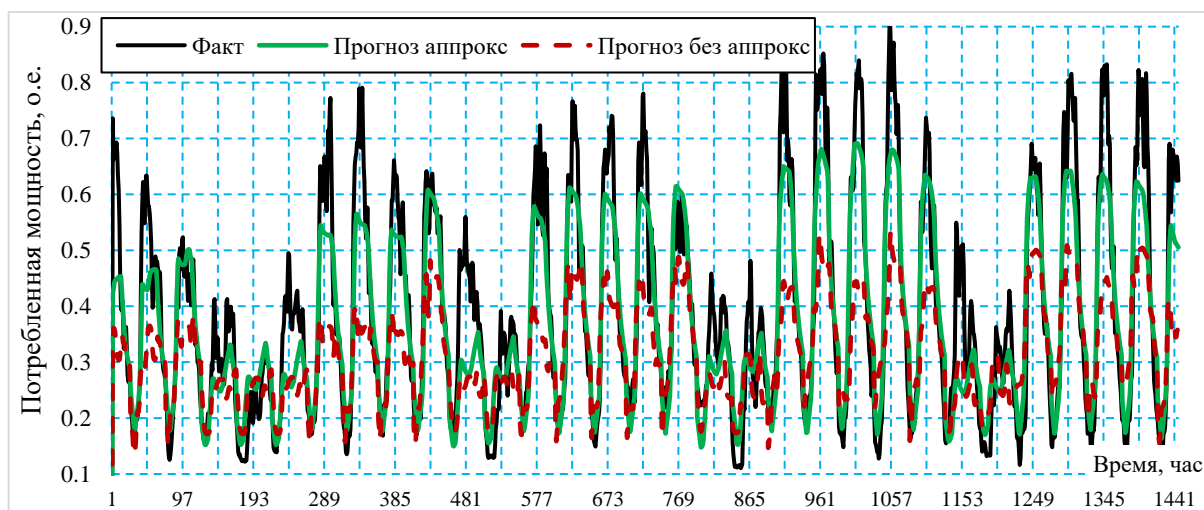


Рисунок 1.18 – Сравнение прогнозных и фактических значений электропотребления для циклического профиля

Таблица 1.8 – Точность прогнозирования входных данных

Состояние выборки \ Тип потребителя	Погрешность прогноза %		
	Циклический	Аддитивно – сезонный	Аддитивный
Без сглаживания	3,03	6,28	5,75
Скользящая медиана	2,91	5,57	5,58
Скользящее среднее	2,51	2,22	4,35
Эксп. скользящее среднее	2,52	5,93	4,72

Преимущество метода, скользящего среднего, заключается в возможности сглаживать краткосрочные колебания, что позволяет повысить точность прогнозирования по сравнению с необработанными данными в среднем на 3%.

1.3.3 Применение метода кластерного анализа в задаче обнаружения аномалий

Предлагаемый метод обработки данных позволяет:

- улучшить аппроксимирующие свойства НС благодаря сведению данных схожего типа в единый кластер, для которого аппроксимирующая функция будет максимально схожа;

- выявлять одиночные (точечные) аномалии (выбросы) – данные, которые резко отличаются от других и выходят за допустимые пределы. Например, кратковременные перегрузки или отключения от электросети у энергопотребителей;
- выявлять коллективные аномалии – последовательности данных, имеющих похожий характер, но которые выходят за допустимые пределы. Могут быть связаны с длительными отключениями от электросети, кражами электроэнергии и другими факторами;
- выявлять контекстные аномалии – последовательности данных, которые резко отличаются от других в том же контексте, но находятся в допустимых пределах. Например, ошибки при передаче данных от приборов учёта.

Обработка выборки данных с помощью метода k -средних. Предлагается разбиение выборки на 3 кластера, что позволит повысить обобщающую способность НС-модели благодаря последовательной подаче на входы НС при обучении близких по величине значений, и обнаруживать нетипичные для конкретного профиля ЭП участки с повышенным или пониженным потреблением.

На рисунке 1.19 приведено визуальное разделение входной выборки на кластеры с использованием метода k -средних.




Рисунок 1.19 – Разделение полного объема выборки на кластеры

На рисунке 1.19, наглядно отражены кластеры с высоким потреблением. Кластеры имеют малое количество объектов и указывают на аномально высокое

или энергопотребление (например, неисправность оборудования или изменении режима работы, о чем говорит внезапный переход из одного кластера в другой). Кластер 3 отражает аномалию (значительное кратковременное изменение потребление ЭЭ). С учетом небольших всплесков, не учитываемых кластеризацией, общее количество аномальных значений составляет $\sim 0.95\%$ от всей выборки, что соответствует диапазонам, рассмотренным в параграфе 1.3.

Экспериментальное исследование. Для исследования влияния кластеризации входных данных перед обучением НС-модели создана НС-модель содержащая следующую структуру: количество нейронов в скрытых слоях 30 и 20; функции активации для каждого слоя – ReLU; эпохи обучения – 650; – BatchSize – 250.

При обучении с кластеризацией, выборка разделялась на подвыборки согласно отнесению данных к тому или иному кластеру. Выборки подавались на вход НС поочередно. Количество эпох и размер пакета оставались неизменными для всех итераций обучения.

На рисунке 1.20 приведено сравнение прогнозных и фактических значений потребленной мощности при кластеризации данных перед обучением и без нее. Потребитель аддитивный. (AP-204).

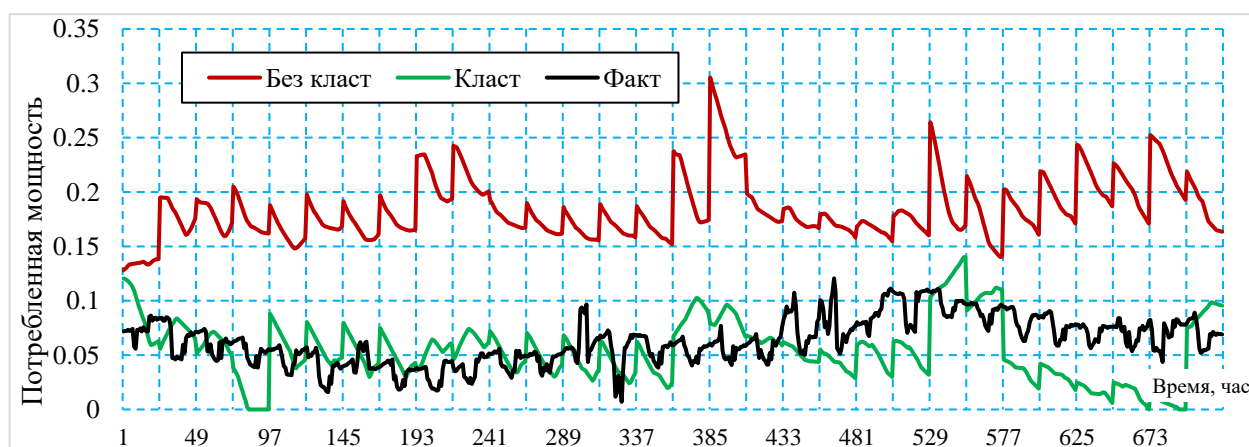


Рисунок 1.20 – Сравнение прогнозных и фактических значений

Рассчитанные значения ошибок прогноза сведены в таблице 1.9 (приведены результаты с использованием ГА и скользящего окна полученные в разд. 4.3.4).

Высокие значения погрешности обусловлены:

- сложностью обучения НС на аддитивных данных;
- настройками НС-моделей (не являются оптимальными).

Таблица 1.9 – Значения ошибок прогнозирования

Методы обработки информации	Характеристики потребителя	Ошибка прогноза %		
		Профиль потребителя электроэнергии		
		Циклический	Аддитивный - 1	Аддитивный - 2
Без кластеризации		7.29	22.60	28.64
С кластеризацией		6.86	11.01	13.54

Проведенный анализ показал, что использование кластеризации позволило повысить точность прогнозирования: – в случае циклического характера потребителя в среднем на 30%, а в случае аддитивного характера потребителя в среднем на 15%.

Исследовано влияние предобработки входных данных для обучения НС прогностической модели на точность прогнозирования. Рассмотрены существующие решения на примере работ [48-51]. В таблице 1.10 сведены значения ошибки прогнозирования, рассчитанные по формуле MAPE для различных способов предобработки. Применяемую совокупность методов предобработки, включающую скользящее среднее, кластеризацию и нормализацию, предлагается обозначить как CMAN (Clusterization, Mean Average, Normalization).

Таблица 1.10 – Сравнение методов обработки данных

Методы предобработки			Ошибка прогнозирования, %
1	MF	заполнение средним, нормализация	4,56
2	CEEMD	метод разложения эмпирического режима ансамбля	1,3
3	FCPS, OTP	метод группировки набора данных, нормализация данных, одноразового кодирования	2,83
4	PCA	метод главных компонент	1,26
5	CMAN	метод кластеризации, скользящее среднее, нормализация	0,96

Проведенный анализ известных исследований влияния обработки данных показал, что CMAN, дает в среднем ошибку прогнозирования ЭП 0,96%, что показывает лучший результат для потребителей с циклическим профилем.

Для наглядного представления сравнение известных результатов работы НС-моделей с предлагаемым методом на основании таблице 1.10 построена диаграмма (рисунок 1.21).




Рисунок 1.21 – Ошибки прогнозирования

Анализ экспериментальных исследований показал, что использование совокупности методов кластеризации, сглаживания и нормализации обеспечивает погрешность прогнозирования в пределах 1%.

Таким образом, проведенный анализ влияния шума и аномалий на качество обучения и работы НС-модели прогнозирования подтвердил необходимость разработки метода предварительной обработки данных, нацеленной на обнаружение и устранение аномалий и шума для повышения качества обучения НС-модели прогнозирования без потери информативности выборки.

Новизной в предложенном методе CMAN для предобработки и анализа данных, применительно к прогнозированию ЭП, является:

- предлагаемая последовательность обработки данных:
 - 1) кластеризация (поиск аномалий, выделение режимов потребления);
 - 2) сглаживание (устранение небольших выбросов, шумов);
 - 3) нормализация (повышение информативности данных для НС).
- получение лучших результатов по сравнению с другими методами (таблица 1.10). При этом CMAN позволяет работать с аддитивными профилями данных, которые не рассматривались в существующих работах.

Однако стоит отметить, что при прогнозировании ЭП для аддитивного потребителя, точность прогноза значительно снижается, и погрешность может со-

ставлять 12% и более. Связано это с характером аддитивного профиля, требующего специализированного подхода к прогнозированию, без которого добиться требуемой точности более 97% при условии отсутствия некоторой информации (например, график работы предприятия, загруженность, циклы производства, план ремонта оборудования и т.д.) практически невозможно.

Таким образом встает проблема повышения точности работы прогностических НС-моделей при работе с аддитивными профилями потребления ЭЭ.

1.4. Разработка программного модуль обработки и идентификации аномалий во входных данных

Задача создания программы по обработке аномалий во входных данных ЭП, перед НС прогнозированием обусловлена необходимостью быстрого и автоматизированного создания актуальных и точных выборок. Решение направлено на уменьшение времени, требуемого для создания выборки, снижения влияния человеческого фактора при ручной разметке и обработке. И как следствие – подготовку выборок для дообучения НС модели на новых данных, поступающих от счетчиков ЭЭ.

Предлагается проводить анализ поступивших данных при помощи скриптов Python. Это позволит обнаружить дубликаты, заполнить пропуски и привести данные к нужному формату перед кластеризацией.

```
# Создаем DataFrame с отдельными столбцами
df = pd.read_excel('2022 1 полугодие.xlsx') #Название файла с тестовыми
данными
Date = df[['Vremya']].values
Date = pd.DataFrame(Date, columns=['dt'])
P = df['Активная энергия'].values
start = '2022-01-01 01:00:00' #Date.iloc[0,0]
end = '2022-07-01 00:00:00' #Date.iloc[-1,0]
# Создаем временной ряд с почасовой частотой
DateD = pd.date_range(start=start, end=end, freq='h')
DateD = DateD.strftime('%d.%m.%Y %H:%M:%S')
DateD = pd.DataFrame(DateD, columns=['DT'])
Date['dt'] = pd.to_datetime(Date['dt'], format='%d.%m.%Y %H:%M:%S')
DateD['DT'] = pd.to_datetime(DateD['DT'], format='%d.%m.%Y %H:%M:%S')
print('start', Date.iloc[0,0])
print('end', Date.iloc[-1,0])
print('DateD',DateD)
print('Date', Date['dt'])
P_dob = []
for dt in DateD['DT']:
    if dt in Date['dt'].values: # Проверяем, есть ли dt в столбце 'dt'
```

```

        index = Date[Date['dt'] == dt].index[0] # Получаем индекс соответ-
ствующего значения
        P_dob.append(P[index]) # Добавляем значение из P
    else:
        P_dob.append(2) # Если нет соответствия, добавляем 2
ND = pd.DataFrame(P_dob)#, columns=['Day', 'Month', 'Year', 'Hour', 'P']
Res = pd.concat([DateD, ND], axis=1)
filename = 'Fixed.xlsx' #Путь к файлу с результатами
Res.to_excel(filename, index=False) #Перезаписываем файл

```

Объяснение: Выполняется чтение файла с данными, формируется временной ряд, соответствующий интервалу в выборке, выполняется поиск пропущенных значений между созданным и реальным временными рядами. Если обе даты совпадают, в столбец с потребленной мощностью записывается соответствующее значение активной или реактивной мощности, если пропуск есть – значение заменяется отличным от данных значением (здесь - 2). Варианты применения:

- на этапе обучения удалить из выборки отмеченные образцы;
- заполнять пропущенные значения при помощи нейросетевого прогноза.

```

Pfix = tdf.iloc[:, 1]
def find_consecutive_values(Pfix, min_length=3):
    result = []
    current_value = None
    current_length = 0
    start_index = 0
    for i, value in enumerate(Pfix):
        if value == current_value:
            current_length += 1
        else:
            if current_length >= min_length:
                result.append((start_index, current_length))
            current_value = value
            current_length = 1
            start_index = i
    if current_length >= min_length:
        result.append((start_index, current_length))
    return result
result = find_consecutive_values(Pfix)
print('На точке учета: ' + точка)
for start_index, length in result:
    print(f"Обнаружены повторяющиеся значения активной мощности, длиной
        в {length} часов, начиная с часа {start_index}:
        {Pfix[start_index:start_index+length]}")

```

Объяснение: выполняется проверка ряда данных о потреблении на предмет одинаковых значений на протяжении 3 часов и более. Выводится сообщение, содержащее сами значения и дату/время в выборке, где они находятся.

Поскольку не все УСПД имеют возможность подключения метеостанций как объекта опроса, возникает проблема с получением метеоданных как для работы НС, так и для создания обучающей выборки.

Предлагается проводить формирование обучающей выборки автоматизировано, в совокупности с применяемыми методами обработки информации (см. раздел 1.3.2). Разработан модуль создания выборки и обработки данных. Окно управления модулем приведено на рисунке 1.22.

Модуль позволяет:

- собирать почасовые данные о погоде из открытого источника;
- проводить сглаживание и кластеризацию данных об ЭП;
- проверять на наличие провалов и дубликатов;
- сводить полученные ряды данных в выборку и сохранять в виде excel файла.

Настройки программы

Интервал дат

Начальная дата: 18.07.2023

Конечная дата: 20.07.2023

Рабочие пути

Путь к драйверу: C:/chromedriver-win64/chromedriver.exe Обзор...

Путь к браузеру: C:/Users/User/AppData/Local/Yandex/YandexBrowser Обзор...

Путь сохранения выборки: C:/OlegProject/ Обзор...

Координаты точки погоды: 48.171;40.325

Имя ряда мощности в Excel: Активная мощность

Путь к файлу с данными: C:/OlegProject/RED.xlsx

Сохранить настройки Начать сборку

Формирование выборки

Рисунок 1.22 – Настройки сбора выборки

После ввода параметров для сбора данных, указания рабочих путей открывается браузер Google Chrome. На открытой странице необходимо указать снимаемый параметр (температура, скорость ветра, количество осадков), и начальную дату. После этого начинается процесс записи данных, при помощи имитации команд от мыши. Записанные параметры объединяются с рядами дат и имеющимися данными об электропотреблении в единый датасет. После записи производится

кластеризация и сглаживание ряда данных ЭП согласно описанным выше методам, сохраняется как полная версия датасета и указанием кластеров, так и разбитая на отдельные кластеры. Алгоритм разработанного программного модуля предобработки данных и формирования выборки приведен на рисунке 1.23.

Данная программа является одним из программных модулей системы ППР, рассматриваемой в 5 главе. Код приведен в приложении В.

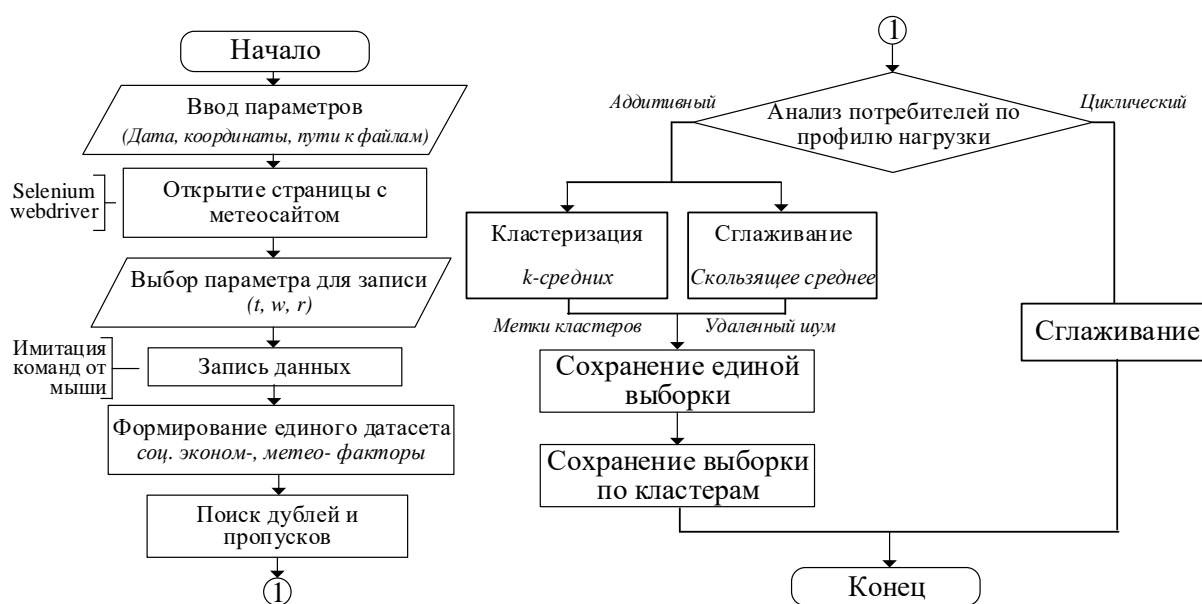


Рисунок 1.23 – Алгоритм работы модуля обработки данных

Таким образом в ходе выполнения исследования выявлена необходимость в автоматизации многоэтапного процесса подготовки выборки (сбор данных, предобработка, формирование датасета). Это позволит:

- автоматически собирать почасовые климатические данные из открытых источников;
- проводить предобработку входных данных об ЭП;
- выявлять наличие провалов и дубликатов в поступающих данных;
- сводить полученные ряды данных в выборку и сохранять в виде excel файла;
- снизить время на подготовку выборки (запись 3 почасовых параметров на год – 3-3.5 часа).

Выводы по главе 1

1) Сформулирована и обоснована проблема, заключающаяся в необходимости обработки неопределенных (содержащих шум и аномалии) данных для точного моделирования и прогнозирования ЭП. С учетом специфики задачи прогнозирования ЭП и ограниченной доступности данных введены ограничения на объем и качество исходных данных, поступающих на вход нейросети.

2) Проведенный анализ литературных источников подтвердил эффективность нейросетевых методов для прогнозирования электропотребления. Однако существующие решения не позволяют прогнозировать нагрузку у потребителей с аддитивным профилем. В ходе исследования были определены основные методы предобработки данных для нейросетей и возможность классификации профилей потребления по коэффициенту вариации и характеру заполнения графика.

3) Применение кластеризации повысило точность прогноза: на 30% для потребителей с циклическим профилем и на 15% — для аддитивного. Для обработки данных предложена совокупность методов, включая скользящее среднее и кластеризацию k-средних, а также скрипты для поиска дублей и заполнения пропусков. Этот подход позволяет обрабатывать данные без удаления аномалий, сохраняя информативность набора.

4) Апробация предложенного подхода к предобработке данных, реализованного в виде модуля «СМАН» показала среднюю ошибку прогнозирования ЭП 0,96%. Однако для аддитивного потребителя точность прогнозирования в некоторых случаях снижается до 88% и менее из-за особенностей профиля, требующего специализированного подхода. Таким образом, возникает проблема повышения точности нейросетевых моделей прогнозирования для аддитивных профилей потребления ЭЭ.

Глава 2. РАЗРАБОТКА МЕТОДА И АЛГОРИТМА НЕЙРОСЕТЕВОГО ПРОГНОЗИРОВАНИЯ В ЗАДАЧАХ ОПТИМИЗАЦИИ ПОТРЕБЛЕНИЯ ЭЛЕКТРОЭНЕРГИИ

Перед созданием НС-модели необходимо исследовать влияние структурных гиперпараметров на точность прогнозирования ЭП.

Учитывая особенности прогнозируемых потребителей и необходимость развертывания НС на реальном оборудовании, накладываются следующие ограничения:

1) Ограничить выбор типа НС затрачиваемыми ресурсами на обучение и работу НС-модели (обучение производится без использования графических или тензорных процессоров при объеме оперативной памяти в 16 Гб).

2) Ограничить работу модели краткосрочным горизонтом прогнозирования электропотребления (до недели).

3) Ориентировать модели на работу с данными с частотой дискретизации 1 час.

Показателем точности прогноза выбран средний модуль процента ошибки (MAPE) (2.1):

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|y'_i - y_i|}{y_i}, \quad (2.1)$$

где n – число часов в выборке, y'_i – прогноз электропотребления в i -й час, y_i – истинное значение электропотребления в i -й час.

Выбор MAPE обусловлен тем, что именно этот показатель используется предприятиями как главная метрика точности прогноза электропотребления при работе на оптовом и розничном рынках электроэнергии и мощности.

Постановка задачи. Для повышения точности прогнозирования ЭП аддитивных потребителей необходимо разработать алгоритм:

- имеющий возможность работы с аддитивными данными, отличающимися сложностью в определении и учете влияющих факторов;
- позволяющий проводить прогнозирование электропотребления с погрешностью не более 3%;
- иметь возможность встраивания в единый программный комплекс в виде модуля;

- обеспечивать достаточное быстродействие и взаимодействие с наименее ресурсозатратными типами НС.

2.1 Робастное обучение нейронных сетей в задачах прогнозирования

Задача регрессионного анализа заключается в построении различных моделей, описывающих функционирование многофакторных систем [52].

Пусть имеется многофакторная система с набором входных факторов F_1, \dots, F_k .

Предположим также, что истинная зависимость отклика Y такой системы от входных факторов может быть описана следующим линейно параметризованным регрессионным уравнением (2.2):

$$y = Z\theta + \varepsilon, \quad (2.2)$$

где $Z = \begin{bmatrix} f_1(z_{11}) & \cdots & f_k(z_{1k}) \\ \vdots & \ddots & \vdots \\ f_1(z_{N1}) & \cdots & f_k(z_{Nk}) \end{bmatrix}$ – неслучайная матрица значений регрессионных

функций, имеющая полный столбцовый ранг, равный числу параметров модели;

$\theta = (\theta_1, \dots, \theta_k)^T$ – вектор неизвестных параметров, значения которых необходимо

оценить, k – число неизвестных параметров, значения которых необходимо оце-

нить, N – количество проведенных экспериментов; $f_i(z)$ – известные действи-

тельные функции вещественного аргумента z , z_{ij} – значения входных факторов

F_1, \dots, F_k , полученные в течение N экспериментов; $y = (y_1, \dots, y_N)^T$ – вектор зна-

чений отклика, $\varepsilon = (\varepsilon_1, \dots, \varepsilon_N)^T$ – вектор случайных ошибок наблюдений, которые

не зависят от значений z_{ij} .

Процесс построения регрессионной модели по своей сути является задачей

статистического оценивания, целью которой выступает максимально точное

определение вектора неизвестных параметров θ на основе имеющихся выбороч-

ных данных – наблюдений за откликом и влияющими факторами [51, 52].

Классическим и наиболее распространенным подходом к решению данной

задачи служит метод наименьших квадратов (МНК), суть которого состоит в ми-

нимизации квадратичного функционала, представляющего собой сумму квадратов невязок – отклонений эмпирически наблюдаемых значений зависимой переменной от модельных, предсказанных уравнением регрессии [51, 52].

Робастная модификация обучения НС. Традиционные подходы к решению задач машинного обучения демонстрируют высокую эффективность преимущественно при работе с «идеальными» данными, соответствующими строгим статистическим предположениям [52]. Однако в практических условиях исходная информация часто характеризуется наличием аномальных наблюдений (выбросов), существенно отклоняющихся от общей выборки, а также сложностью разделения данных на аномалии и нормальное потребление. Данная ситуация обусловлена тем, что реальные данные являются продуктом эмпирических измерений, подверженных погрешностям оборудования или человеческого фактора, либо отражают объективную сложность и неоднородность изучаемых процессов. Указанные особенности могут критически снижать точность прогнозов при использовании классических алгоритмов.

Одним из способов смягчения данной проблемы служит этап предварительной обработки данных с применением фильтрации аномальных значений. Вместе с тем, стандартные методики удаления выбросов, приведенные в [53], способны вызвать невосполнимую утрату содержательной информации, что наглядно демонстрирует следующий пример из [54]. Предположим, что оценка параметров линейной регрессии выполняется по пяти наблюдениям (серые точки на рисунке 2.1). Прямая, проведенная через точку А, отражает истинную функциональную зависимость.




Рисунок 2.1 – Влияние выброса на оценивание параметров линейной регрессии

Присутствие единственного выброса в данных провоцирует резкий рост суммы квадратов остатков, что существенно искажает оценки параметров, получаемые по методу наименьших квадратов (МНК). В качестве альтернативы предлагается использовать робастные методы, направленные не на исключение аномалий, а на минимизацию их деструктивного влияния на модель [55, 56].

Для получения устойчивых оценок можно использовать одну из следующих робастных функций потерь [52]:

1) Функция потерь Хьюбера

$$\rho(z) = \begin{cases} \frac{1}{2}z^2 & |z| \leq \beta, \\ \beta|z| - \frac{1}{2}\beta^2 & |z| > \beta. \end{cases}$$

2) Функция потерь Эндрюса

$$\rho(z) = \begin{cases} \beta \left(1 - \cos \frac{z}{\beta} \right), & |z| < \pi\beta, \\ 2\beta, & |z| \geq \pi\beta. \end{cases}$$

3) Функция потерь Коши (Лоренца)

$$\rho(z) = \ln \left(\frac{1}{2} \left(\frac{z}{\beta} \right)^2 + 1 \right),$$

4) Функция потерь Тьюки

$$\rho(z) = \begin{cases} z^2, & |z| \leq \beta, \\ \beta^2, & |z| > \beta. \end{cases}$$

5) Функция потерь Рамсея

$$\rho(z) = \frac{1 - (1 + \beta|z|) \exp(-\beta|z|)}{\beta^2},$$

6) Функция потерь «Fair»

$$\rho(z) = \beta^2 \left(\frac{|z|}{\beta} - \ln \left(1 + \frac{|z|}{\beta} \right) \right).$$

где z – разница между фактическим и прогнозным значением, β – пороговый параметр, определяющий границу переключения между двумя поведением функции.

В рамках последующей работы были задействованы две функции потерь: Хьюбера, чей параметр определяет не только поведение функции на отдельных интервалах области определения, но и границы этих интервалов, а также Коши, параметр которой регулирует поведение функции во всей области определения. Анализ применимости указанных функций потерь в контексте повышения точности прогнозирования для аддитивного типа профиля электропотребления, а также полученные результаты, будут подробно изложены в разделе 4.3.3.

Алгоритм робастного обучения нейронной сети. Поскольку полностью избавиться от выбросов и аномалий в выборке данных невозможно без потери информативности, предлагается для из минимизации воспользоваться робастной модификацией метода обратного распространения ошибки [57].

Входное значение для каждого нейрона j на слое n его выходное значение $o_j^{(n)}$ определяется в соответствии с выражением:

$$o_j^{(n)} = \varphi\left(s_j^{(n)}\right),$$

где φ – функция активации нейронов, $s_j^{(N)}$ – входное значение j -го нейрона на слое.

Тогда выходные значения НС будут вычисляться как

$$y_k = \varphi\left(s_j^{(N)}\right). \quad (2.3)$$

Таким образом, выходные значения нейронной сети зависят от всей совокупности ее весовых коэффициентов. На этапе инициализации все веса задаются в виде случайных величин, характеризующихся малыми численными значениями. Как отмечено в работах [57, 58], в рамках одной эпохи обучения возможны три способа корректировки весов. Первый способ заключается в обновлении весов после подачи на вход каждого отдельного образца из обучающей совокупности. Вторым способом связан с применением мини-пакетного обучения, заключающегося в подаче на вход НС поочередно образцов, объединенных в т.н. батчи (batch) и корректировки весов после обработки каждого пакета. Третий способ предполагает подачу на вход НС всей выборки за один раз, корректировка весовых значений выполняется соответственно после обработки все элементов выборки.

Для решения задач прогнозирования и классификации наиболее распространены первые 2 метода, как наименее ресурсозатратные.

Рассмотрим обучение НС методом обратного распространения на примере первого варианта. При этом второй способ будет аналогичен первому, но расчет ошибки производится не для каждого элемента, а для пакета (Batch).

Суммарная функция потерь E может быть представлена как сумма значений функций потерь $f(t_j, y_j)$ на каждом выходе НС. Поэтому обучение сети сводится к решению следующей задачи оптимизации:

$$E = \sum_{j=1}^{l^{(N)}} f(t_j, y_j) \rightarrow \min_{\omega_{ij}^{(1)}, \dots, \omega_{ij}^{(N-1)}}, \quad (2.4)$$

где t_j – требуемый ответ на j -м выходе сети – определяется следующим образом,

$w_{ij}^{(N)}$ – веса на ребрах между нейронами первого и второго слоя, $l^{(N)}$ – количество нейронов на слое, y_j – получаемый ответ на выходе НС, а t_j вычисляется как:

$$t_j = \begin{cases} 1, & X_m \in q_j \\ 0, & \text{иначе} \end{cases},$$

где $X_m \in q_j$ – принадлежность объекта X_m к классу q_j .

Как правило, в качестве функции потерь используется квадратичная функция типа:

$$f(t_j, y_j) = \frac{1}{2}(y_j - t_j)^2. \quad (2.5)$$

Нейросети, в которых применяется квадратичная функция потерь, будем именовать классическими. Чтобы минимизировать общую функцию потерь, требуется определить ее производную по весовым коэффициентам сети. На основании выражений (2.3) и (2.4) частная производная находится с помощью цепного правила [58]:

$$E'_{ji}{}^{(n)} = \frac{\partial E}{\partial \omega_{ij}^{(n-1)}} = \frac{\partial E}{\partial o_j^{(n)}} \frac{\partial o_j^{(n)}}{\partial s_j^{(n)}} \frac{\partial s_j^{(n)}}{\partial \omega_{ij}^{(n-1)}},$$

где $o_j^{(n)}$ – выходное значение нейрона, $s_j^{(n)}$ – входные значения нейронов, $\omega_{ij}^{(n-1)}$ – весовые значения нейронов.

Во входном значении нейрона $s_j^{(n)}$ от $\omega_{ij}^{(n-1)}$ зависит только одно слагаемое, таким образом:

$$\frac{\partial s_j^{(n)}}{\partial \omega_{ij}^{(n-1)}} = \frac{\partial}{\partial \omega_{ij}^{(n-1)}} \left(\sum_{i=1}^{l^{(n-1)}} \omega_{ij}^{(n-1)} o_i^{(n-1)} \right).$$

Производная выходного значения нейрона $o_j^{(n)}$ по его входному значению $s_j^{(n)}$ – это производная функции активации:

$$\frac{\partial o_j^{(n)}}{\partial s_j^{(n)}} = \frac{d\varphi(s_j^{(n)})}{ds_j^{(n)}}.$$

Если нейрон находится на выходном слое, то $n = N$ и первый множитель в производной выходного значения нейрона можно легко вычислить, поскольку $o_j^{(n)} = y_j$:

$$\frac{\partial E}{\partial o_j^{(N)}} = \frac{\partial E}{\partial y_j} = \frac{\partial f(y_j, t_j)}{\partial y_j}.$$

Теперь получим выражение для производной E по $o_j^{(n)}$ в случае, когда n – произвольный внутренний слой сети. Для этого рассмотрим E как функцию от входных значений нейронов следующего слоя:

$$E = E(s_k^{(n+1)}), k = 1, \dots, l^{(n+1)},$$

а затем возьмем производную по $o_j^{(n)}$ [52]:

$$\frac{\partial E}{\partial o_j^{(n)}} = \sum_{k=1}^{l^{(n+1)}} \left(\frac{\partial E}{\partial s_k^{(n+1)}} \frac{\partial s_k^{(n+1)}}{\partial o_j^{(n)}} \right) = \sum_{k=1}^{l^{(n+1)}} \left(\frac{\partial E}{\partial s_k^{(n+1)}} \frac{\partial s_k^{(n+1)}}{\partial o_j^{(n)}} \right) w_{jk}^{(n)}.$$

где $\omega_{ij}^{(N)}$ – веса на ребрах между нейронами первого и второго слоя, $o_j^{(n)}$ – входное значение для каждого нейрона, E – частная производная,

Производную функции активации можно вычислить, если известны все производные по выходным значениям для следующего слоя.

Таким образом, производная суммарной функции потерь будет вычисляться в соответствии с:

$$E_{ij}^{(n)} = \delta_j^{(n)} o_i^{(n-1)},$$

где $\delta_j^{(n)}$, исходя из приведенных выше формул, вычисляется следующим образом:

$$\delta_j^{(n)} = \frac{\partial E}{\partial o_j^{(n)}} \frac{\partial o_j^{(n)}}{\partial s_j^{(n)}} = \begin{cases} \frac{\partial f(y_j, t_j)}{\partial y_j} \varphi'(y_j), & n = N, \\ \left(\sum_{k=1}^{l^{(n+1)}} w_{jk}^{(n)} \delta_k^{(n+1)} \right) \varphi'(s_j^{(n)}), & \text{иначе.} \end{cases} \quad (2.6)$$

Поскольку соотношение для вычисления производной известно, для решения задачи оптимизации можно воспользоваться методом градиентного спуска [58]. В этом случае корректировка весов $\Delta \omega_{ij}^{(n-1)(p)}$ на итерации p имеет вид:

$$\omega_{ij}^{(n-1)p} = \omega_{ij}^{(n-1)(p-1)} + \Delta \omega_{ij}^{(n-1)p}.$$

В данном соотношении $\Delta \omega_{ij}^{(n-1)(p)}$ вычисляется как

$$\Delta \omega_{ij}^{(n-1)p} = -\eta E_{ji}'^{(n)(p)} = -\eta \delta_j^{(n)(p)} o_i^{(n-1)(p)}, \quad (2.7)$$

где $\eta > 0$ – скорость обучения сети, $E_{ji}'^{(n)(p)}$ – производная суммарной функции потерь на итерации p , а на итерации p вычисляется в соответствии с соотношением (2.6), в котором вместо весов $\omega_{jk}^{(n)}$ используются веса $\Delta \omega_{ij}^{(n-1)(p)}$.

При реализации алгоритма обратного распространения ошибки в качестве функции активации используют классические функции потерь – квадратичные (2.5). Однако при наличии выбросов и аномалий в данных во время обучения возникает значительное изменение градиента ошибки, что влечет за собой резкое изменение весовых значений, что снижает качество обучения НС и увеличение времени сходимости.

В работе [52] предлагается модификация данного алгоритма обратного распространения ошибки заключается в использовании робастной функции потерь вместо квадратичной, например, функцию Хьюбера или Коши.

Для минимизации суммарной функции потерь необходимо вычислить её производную по весам нейронной сети. Частная производная вычисляется по следующему цепному правилу:

$$E_{ji}'^{(n)} = \frac{\partial E}{\partial \omega_{ij}^{(n-1)}} = \frac{\partial E}{\partial o_j^{(n)}} \frac{\partial o_j^{(n)}}{\partial s_j^{(n)}} \frac{\partial s_j^{(n)}}{\partial \omega_{ij}^{(n-1)}}, \quad (2.8)$$

Замена квадратичной функции потерь (2.5) на робастную не влияет на структуру нейронной сети, при этом множитель $\frac{\partial E}{\partial o_j^{(N)}} = \frac{\partial E}{\partial y_j} = \frac{\partial f(y_j, t_j)}{\partial o_j^{(N)}}$ нейрона на

выходном слое теперь примет вид:

$$\frac{\partial E}{\partial o_j^{(N)}} = \frac{\partial E}{\partial y_j} = \frac{\partial f_R(y_j, t_j)}{\partial o_j^{(N)}},$$

где f_R – робастная функция потерь, y_j – выходное значение нейрона, t_j – ожидаемое значение на выходе НС.

Производная суммарной функции потерь будет вычисляться в соответствии с

$$E_{ij}^{(n)} = \delta_j^{(n)} o_i^{(n-1)},$$

где множитель $\delta_j^{(n)}$ вычисляется следующим образом:

$$\delta_j^{(n)} = \frac{\partial E}{\partial o_j^{(n)}} \frac{\partial o_j^{(n)}}{\partial s_j^{(n)}} = \begin{cases} \frac{\partial f(y_j, t_j)}{\partial y_j} \varphi'(y_j), & n = N, \\ \left(\sum_{k=1}^{l^{(n+1)}} \omega_{jk}^{(n)} \delta_k^{(n+1)} \right) \varphi'(s_j^{(n)}), & \text{иначе.} \end{cases} \quad (2.9)$$

где $s_j^{(n)}$ – входные значения нейронов на втором слое, φ' – производная функции активации, $\omega_{jk}^{(n)}$ – весовые значения нейронов.

Поскольку структура сети фиксирована, цепное правило (2.8) для вычисления производных на любом ее скрытом слое остается неизменным. Это означает, что выражение для расчета градиента общей функции потерь также не претерпит изменений. На основании утверждения, доказанного в [52], возможна модификация алгоритма обратного распространения ошибки, которая затрагивает лишь замену формулы производной выходного значения нейрона, в то время как остальные этапы алгоритма сохраняются.

Таким образом, ключевая идея модификации состоит в использовании робастной, а не классической квадратичной (MSE) функции потерь. Это позволяет адаптировать алгоритм обратного распространения для работы с данными, содержащими шум и аддитивные помехи, существенно снижая чувствительность

процесса обучения к аномальным выбросам. Поскольку у квадратичных функций потерь при больших ошибках в местах выбросов в данных, градиент принимает большие значения, что приводит к резким и нестабильным изменениям весов НС. При этом робастная функция потерь, на примере Хьюбера:

- если значения ошибки находятся в допустимом интервале значений – ведет себя как MSE;
- если значения ошибки большие – переход на линейную зависимость с ограничением градиента константой β (линейный штраф).

Применение предлагаемой модификации метода обучения позволяет сохранить хорошо зарекомендовавший себя метод обратного распространения ошибки. При этом появляется возможность использовать различные функции потерь для построения робастной нейросетевой модели. Результаты проведенного исследования опубликованы в [59].

2.2. Модификация метода прогнозирования электропотребления на основе нейросетевой модели для аддитивного потребителя

Для решения задач прогнозирования ЭП аддитивных потребителей при помощи нейросетей традиционно используются сети типа RNN (рекуррентные) или LSTM. Однако LSTM требует большого количества времени как на настройку, так и значительных вычислительных мощностей для обучения и работы. В свою очередь, RNN страдает от проблемы затухания градиентов, что затрудняет обучение на длинных временных последовательностях. Предлагается использовать подход к прогнозированию ЭП для потребителей с аддитивным профилем на основе авторегрессии. Это позволит применять более простые и менее требовательные к ресурсам нейронные сети типа многослойный персептрон.

Метод скользящего окна использует принцип прогнозирования с шагом на один час (либо полчаса), при котором каждое полученное прогнозное значение служит исходной точкой для построения следующего предсказания. Последовательное повторение данной процедуры позволяет получить прогноз на любой заданный временной интервал. При таком подходе формируется так называемое

окно — совокупность значений за предыдущие временные интервалы, что в подавляющем большинстве случаев способствует повышению достоверности прогнозных результатов.

Задача прогнозирования формулируется следующим образом: зная предыдущие значения временного ряда x , предсказать последующее значение. Образец данных в выборке будет иметь вид:

$$x(t - q + 1), \dots, x(t - 1), x(t), \eta_1, \eta_2, \dots, \eta_g,$$

где q — ширина окна ретроспективных значений, d — шаг прогнозирования, η — независимые переменные (влияющие факторы), g — количество независимых переменных.

Алгоритм работы данного метода представлены на рисунке 2.2.

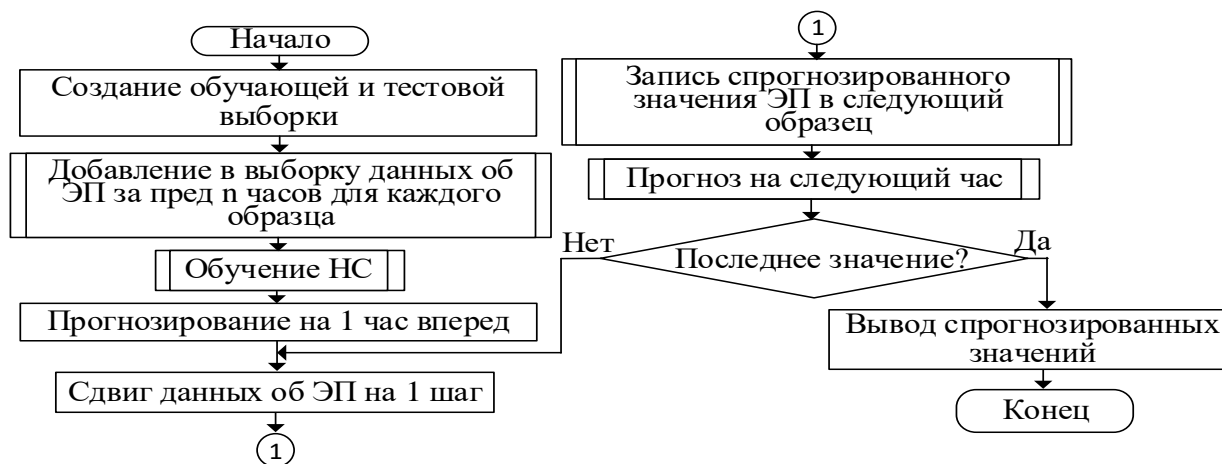


Рисунок 2.2 – Алгоритм прогнозирования электропотребления с использованием скользящего окна

Однако повсеместное применение метода скользящего окна не представляется возможным из-за вероятности ухудшения точности прогнозирования для потребителей с циклическим профилем потребления. Также применение данного метода для средне срочного и долгосрочного прогнозирования вызывает снижение точности по причине накопления ошибки от предыдущих прогнозов.

Эксперимент. Рассмотрим примеры прогнозирования НС со скользящим окном. В данном исследовании при обучении НС-модели использованы данные электропотребления различными типами потребителей электроэнергии с различным характером потребления (циклический, аддитивный).

Основная гипотеза данного исследования заключается в возможности повысить точность краткосрочного прогнозирования электропотребления в частности для потребителей с аддитивным профилем за счет использования алгоритма скользящего окна.

Электропотребление (почасовая мощность нагрузки) является целевой переменной. Выборка содержит записи с шагом в 1 час за 3,5 года (2021–2024 гг.). Таким образом, выборка содержит 30660 строк и 9 столбцов.

На рисунке 2.3 представлены результаты тестирования НС-модели прогнозирования электропотребления, когда данные активной мощности изменяются по какой-либо закономерности.

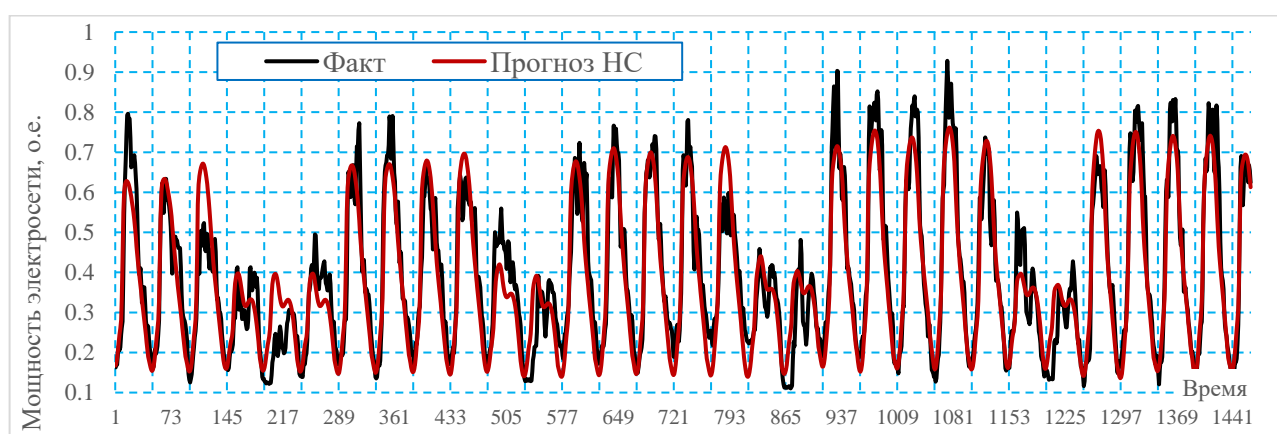


Рисунок 2.3 – Сравнение фактических $P_{факт}$ и прогнозных $P_{прог}$ зависимостей электропотребления

На рисунке 2.4 представлены результаты тестирования НС-модели прогнозирования электропотребления, когда данные аддитивные



Рисунок 2.4 – Тестирование НС-модели прогнозирования (сравнение фактических и прогнозных данных).

Результаты расчета абсолютной ошибки прогноза НС в зависимости от характера входных воздействий с использованием различных типов НС, сведены в таблице 2.1.

Таблица 2.1 – Погрешность прогноза НС от характера входных воздействий

Характер потребителя электроэнергии	Погрешности прогноза нейросети, %	
	Без скользящего окна	Со скользящим окном
Аддитивный	1.71	0.93
Циклический	2.52	0.91

Проведенный анализ результатов расчета погрешностей прогнозирования (таблица 2.1) показал, что:

- наличие скользящего окна в среднем улучшило результаты на 1.2%;
- прогнозы НС обученной на аддитивных данных, гораздо более чувствительны к изменениям структуры входных воздействий;
- подбор гиперпараметров нейронной сети вручную, процесс, который занимает много времени и требует анализа большого количества данных;

Результаты исследования позволили определить рациональный размер окна (длительности ретроспективных данных) равный 24 часам для выбранного метода скользящего окна.

2.3 Выбор метрики при обучении нейронной сети

Для контроля качества обучения НС-модели в ходе обучения существуют различные метрики. При этом различные метрики применяются для различных задач, поэтому важно подобрать наиболее подходящую. Рассмотрим известные метрики для задач регрессии.

Метрики для задач регрессии [60]. Mean Absolute Error (MAE) – измеряет среднюю абсолютную ошибку между предсказанными и реальными значениями. Она показывает, насколько в среднем предсказания модели отклоняются от истинных значений. MAE легко интерпретировать, так как она выражена в тех же единицах, что и исходные данные.

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i|, \quad (2.10)$$

где x_i – фактическое значение данных в i -й точке; y_i – прогнозное значение данных в i -й точке.

Mean Squared Error (MSE) – измеряет среднеквадратичную ошибку. Она более чувствительна к большим ошибкам, чем MAE, так как квадратичная функция ошибки увеличивает влияние больших отклонений.

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2, \quad (2.11)$$

где x_i – фактическое значение данных в i -й точке; y_i – прогнозное значение данных в i -й точке.

Root Mean Squared Error (RMSE) – это квадратный корень из MSE. Она также чувствительна к большим ошибкам, но выражена в тех же единицах, что и исходные данные. RMSE часто используется в задачах, где важно учитывать, как средние, так и большие ошибки. RMSE количественно определяет, насколько хорошо предсказанные значения модели соответствуют фактическим наблюдаемым значениям в наборе данных.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2}, \quad (2.12)$$

где x_i – фактическое значение данных в i -й точке; y_i – прогнозное значение данных в i -й точке, n – количество образцов.

R-squared (R^2) – измеряет долю дисперсии, объясненную моделью. Значение ближе к 1 указывает на хорошую модель. R^2 показывает, насколько хорошо модель объясняет вариативность данных, и является важной метрикой для оценки общей производительности модели.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - y_i)}{\sum_{i=1}^n (x_i - y_i)^2}, \quad (2.13)$$

где x_i – фактическое значение данных в i -й точке; y_i – прогнозное значение данных в i -й точке, n – количество образцов.

В эксперименте для оценки влияния различных метрик на точность прогнозирования электропотребления использовались данные присоединений, различающиеся по характеру электропотребления, причем в роли функции потерь выступала устойчивая к выбросам функция Хьюбера. Исследование проводилось с использованием нейросетевой модели, структурные параметры которой устанавливались экспериментальным путем: три скрытых слоя с числом нейронов 40, 40 и 30 соответственно, величина пакета – 250, количество эпох при обучении – 60, а в качестве функции активации для всех слоев выбрана ReLU.

На рисунке 2.5 приведены графики сравнения полученных прогнозных и фактических значений электропотребления при использовании различных метрик.

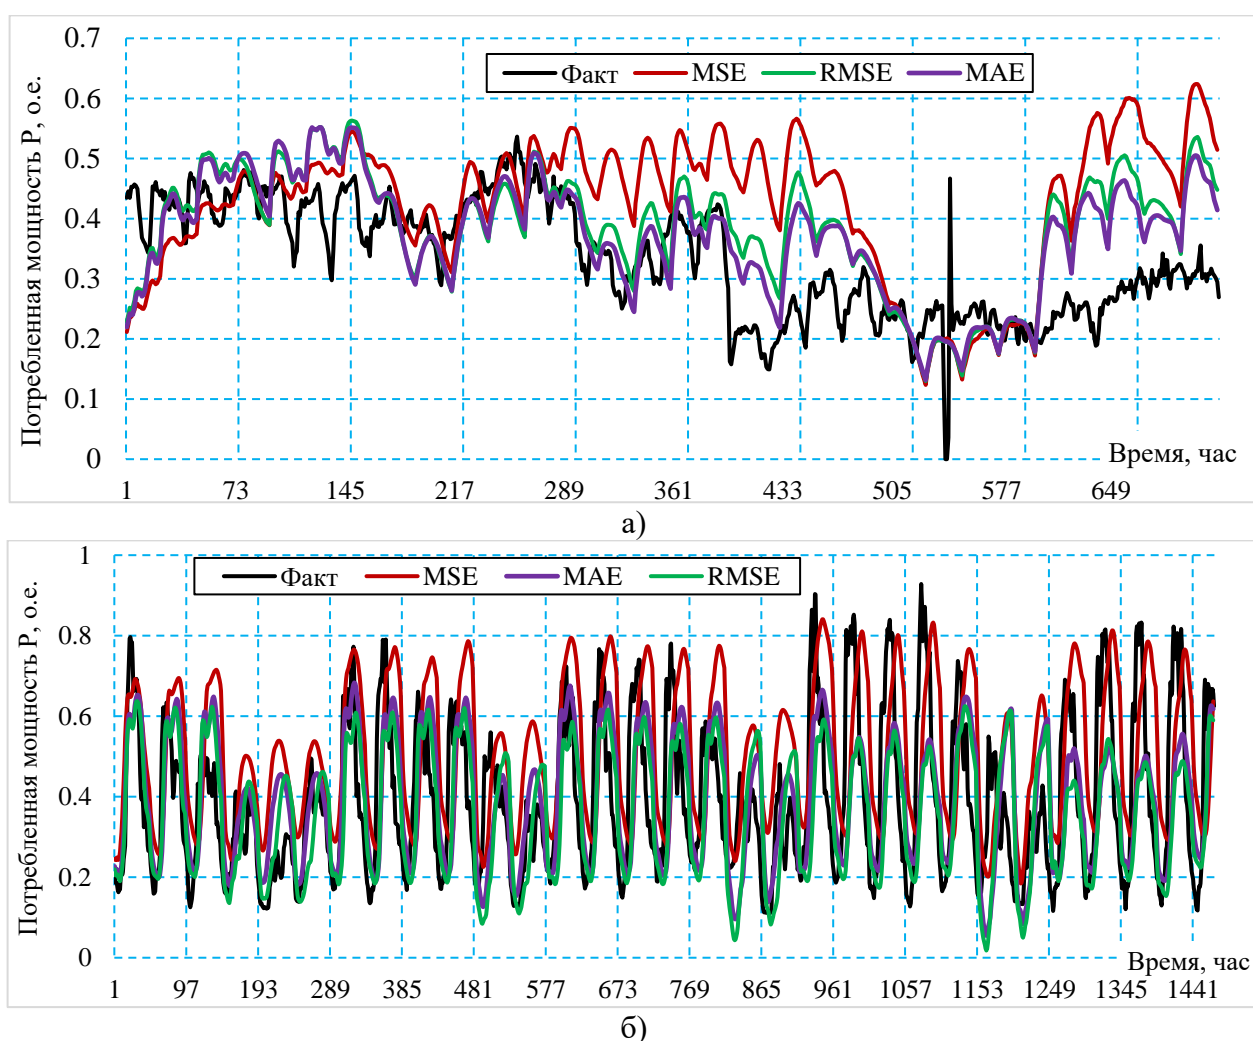


Рисунок 2.5 – Графики сравнения прогнозных и фактических значений для присоединений с профилем: а) аддитивный; б) циклический

Исследовались такие метрики как: MAE, MSE и RMSE. Результаты расчета погрешности прогнозирования сведены в таблицу 2.2

Таблица 2.2 – Погрешности прогнозирования при различных метриках

Метрика	Характер потребления		
	Аддитивно-сезонный	Аддитивный	Циклический
MAE	4,01	4,9	0,19
MSE	24,51	11,9	8,98
RMSE	23,96	15,61	7,21

Анализ графиков (рисунок 2.5) и результатов расчета погрешности (таблица 2.2) показал, что в задаче прогнозирования электропотребления лучший результат показывает метрика MAE снижая ошибку в среднем на 4%.

2.4 Структурная оптимизация нейросети

Структурная оптимизация нейросети это процесс поиска оптимальной архитектуры сети, которая соответствует прикладной задаче, данным и даёт наилучший результат. Целью оптимизации является снижение сложности нейросети, так как по мере её усложнения увеличивается количество параметров и необходимых вычислений. Это затрудняет установку и эксплуатацию систем искусственного интеллекта на периферийных устройствах.

Существует набор параметров НС, называемых гиперпараметрами, которые невозможно определить и уточнить в процессе обучения. Структурная оптимизация нейросети сводится к оптимизации целевой функции вида:

$$E(Fa, n, j, O, Bs, x, y(x, w)), \quad (2.14)$$

где E – целевая функция ошибки прогнозирования, Fa – функция активации нейронов, n – количество нейронов в скрытом слое, j – количество скрытых слоев, O – оптимизатор, Bs – размер пакета, x – входные значения, y – выходные значения, w – весовые значения.

2.4.1 Оценка качества обучения нейросети от ее структуры

Проведение оптимизации по различным направлениям является неотъемлемой частью процесса обучения НС, в том числе, при решении задачи создания сетей для краткосрочного прогнозирования потребления ЭЭ. Ключевая цель оптимизации в рамках машинного обучения состоит в поиске таких параметров модели, которые позволяют существенно минимизировать значение функции потерь $J(n)$. Набор этих параметров, известных как свободные параметры сети, калибруется в ходе обучения на основе предоставленного тренировочного датасета [61].

Влияние размера пакета (BatchSize). Данный параметр напрямую влияет на скорость обучения модели, ее эффективность и временные затраты, необходимые для достижения состояния сходимости. На рисунке 2.6 визуализирована корреляция между точностью прогнозирования (отклонением прогноза нейросети) и устанавливаемым размером пакета.




Рисунок 2.6 – Зависимость отклонения прогнозирования НС, от задаваемого размера пакета

Эффективность обучения НС рассчитывается по формуле (2.15):

$$E = \frac{\Delta l}{t} 100\% \quad (2.15)$$

где E – эффективность обучения, Δl – разность значений ошибки на первой и на последней эпохе, t – время, затраченное на обучение.

Проведенный анализ рисунка 2.6 показал, что увеличение размера пакета входных данных способствует повышению эффективности обучения нейронной сети. С другой стороны, рост этого показателя ведет к повышенным требованиям к объему оперативной памяти. В связи с этим, для всех последующих экспериментов был выбран размер пакета, равный 250, который определен как оптимальный для конфигурации ПК с 8 ГБ ОЗУ.

Влияние количества слоев. Для случая аддитивных входных параметров исследовано влияние количества скрытых слоев нейросети типа многослойный перцептрон (МП) на скорость обучения. Сравнение кривых снижения ошибки при обучении приведено на рисунке 2.7.

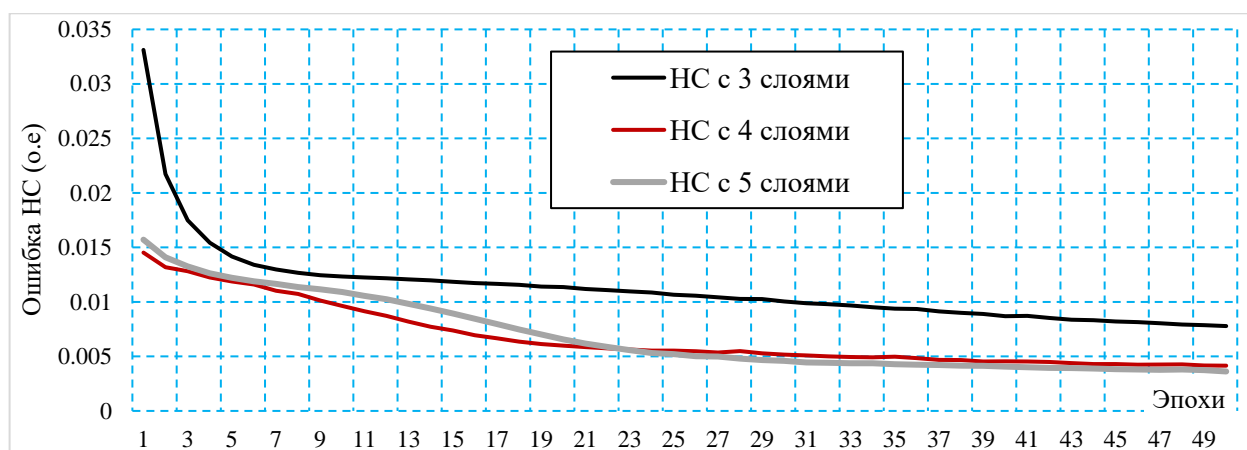


Рисунок 2.7 – Влияние количества слоев на скорость обучения НС

Наблюдается понижение ошибки НС прогнозирования с разным количеством слоев. Результаты погрешностей НС-модели с разным количеством слоев, в случае аддитивного характера электропотребления, представлены в таблице 2.3.

Таблица 2.3 – Влияние количества слоев на точность предсказаний НС

Количество слоев в НС	Количество эпох	Среднее отклонение предсказаний НС, %
3	47	17,10
4	24	13,72
5	24	0,79

Таким образом, проведенное экспериментальное исследование (рисунка 2.7, таблица 2.3), позволило определить, увеличение количества скрытых слоев целесообразно для повышения точности и улучшения сходимости НС-модели.

Влияние оптимизатора. Оптимизаторы – это алгоритмы, применяемые в процессе обучения НС. Их задача определять то, как будут изменяться в ходе обучения такие параметры модели как значения весов и смещения. Это позволяет минимизировать функцию потерь. Рассмотрим наиболее распространенные оптимизаторы:

Стохастический градиентный спуск (SGD) – представляет собой итеративный метод оптимизации, который часто используется в области машинного обучения и глубокого обучения. Этот метод является модификацией классического градиентного спуска, при котором обновления параметров модели (весов) происходят на основе градиента функции потерь, рассчитанного на случайно выбранном подмножестве обучающих данных, а не на всем наборе данных, т. е. на каждой итерации изменение весов происходит по формуле:

$$w_{N+1} = w_N - \alpha \nabla_w E(w; x^{(i)}; y^{(i)}),$$

где E – целевая функция ошибки, зависящая от параметров: w – весовые коэффициенты нейронной сети, α – скорости обучения, $(x^{(i)}, y^{(i)})$ – i -й обучающий набор, N – номер образца. Таким образом, в данном методе веса нейронной сети обновляются в направлении, противоположном направлению градиента целевой функции с шагом, определяемым скоростью обучения [62].

Среднеквадратичное распространение корня (RMSprop) – это экспоненциально затухающее среднее значение. Существенным свойством RMSprop является то, что данный оптимизатор не ограничивается только суммой прошлых градиентов, но RMSprop более ограничен градиентами последних временных шагов. RMSprop вносит свой вклад в экспоненциально затухающее среднее значение прошлых «квадратичных градиентов».

Математическая формулировка выглядит следующим образом:

1) Вычисление градиента g_t на временном шаге t :

$$g_t = \nabla_{\theta}.$$

2) Обновление скользящего среднего квадратов градиента:

$$E[g^2]_t = \gamma E[g^2]_{t-1} + (1 - \gamma),$$

где γ – скорость снижения (определяет, насколько быстро уменьшается скользящее среднее квадратов градиентов. Обычно используется значение по умолчанию 0,9).

3) Обновление параметра θ с использованием скорректированной скорости обучения:

$$\theta_{e+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \varepsilon}},$$

где η – скорость обучения (управляет размером шага при обновлении параметров. RMSProp обычно использует скорость обучения по умолчанию 0,001), ε – константа небольшой величины, добавленная для численной стабильности (по умолчанию для RMSprop принимается принимается 10^{-8}).

Адаптивная оценка момента (Adam) – один из самых эффективных алгоритмов оптимизации в обучении нейронных сетей. Adam сочетает в себе идеи RMSProp и оптимизатора импульса. Расчет матриц оптимизатором Adam можно описать системой уравнений:

$$\begin{cases} V_{dW} = \beta_1 V_{dW} + (1 - \beta_1) dW; \\ S_{dW} = \beta_2 S_{dW} + (1 - \beta_2) dW^2; \\ V_{dW}^{corr} = V_{dW} (1 - \beta_1^t); \\ S_{dW}^{corr} = S_{dW} (1 - \beta_2^t); \\ W = W - \alpha V_{dW}^{corr} (\sqrt{S_{dW}^{corr} + \varepsilon})^{-1} \end{cases},$$

где V_{dW} – матрица скорости изменения параметров; β_1, β_2 – баланс между учетом предыдущего направления градиента и направления градиента; dW – матрица градиентов, задающих направление повышения ошибки; S_{dW} – степень изменения параметров ИНС без учета направления изменения; t – номер пакета при обучении; W – матрица весов; α – величина шага обучения; ε – положительное число для предотвращения деления на ноль.

Оценка качества обучения НС. Для сравнения эффективности алгоритмов оптимизации при обучении нейронной сети прогностического типа был проведён анализ скорости сходимости, приведенный на рисунке 2.8.

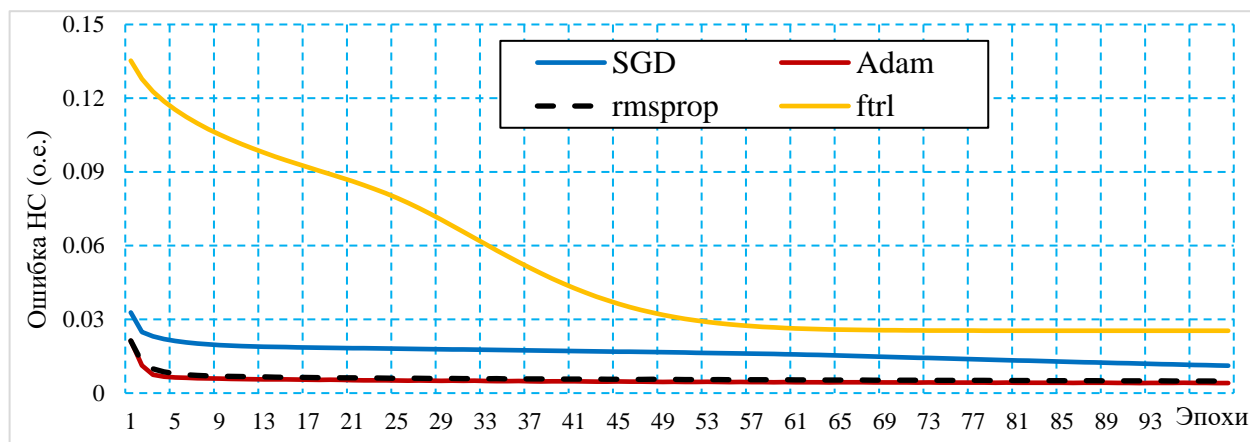


Рисунок 2.8 – Скорость снижения ошибки НС в зависимости от типа оптимизатора

Таким образом, визуальный анализ скорости сходимости НС-модели с различными оптимизаторами, выявил, что наилучшие результаты демонстрируют оптимизаторы “Adam” и “RMSprop”. В этих оптимизаторах используется адаптивное снижение скорости обучения НС-модели, оно:

- улучшает усвоение сложных шаблонов (на 100 эпохе значение ошибки MSE при обучении на ~20% ниже);
- повышает точность модели. Если всегда использовать одну и ту же скорость обучения, нельзя получить модель с максимальной точностью. Снижение скорости обучения позволяет регулировать этот параметр во время обучения.

Влияние функции активации. В качестве функций активации нейронов НС допустимо использовать различные варианты, однако сложилась практика выделения набора функций, считающихся оптимальными применительно к решаемым задачам [63]. Для определения наиболее эффективной функции активации проведен сравнительный анализ динамики уменьшения погрешности нейронной сети в зависимости от выбранной функции активации, иллюстрированный на рисунке 2.9.

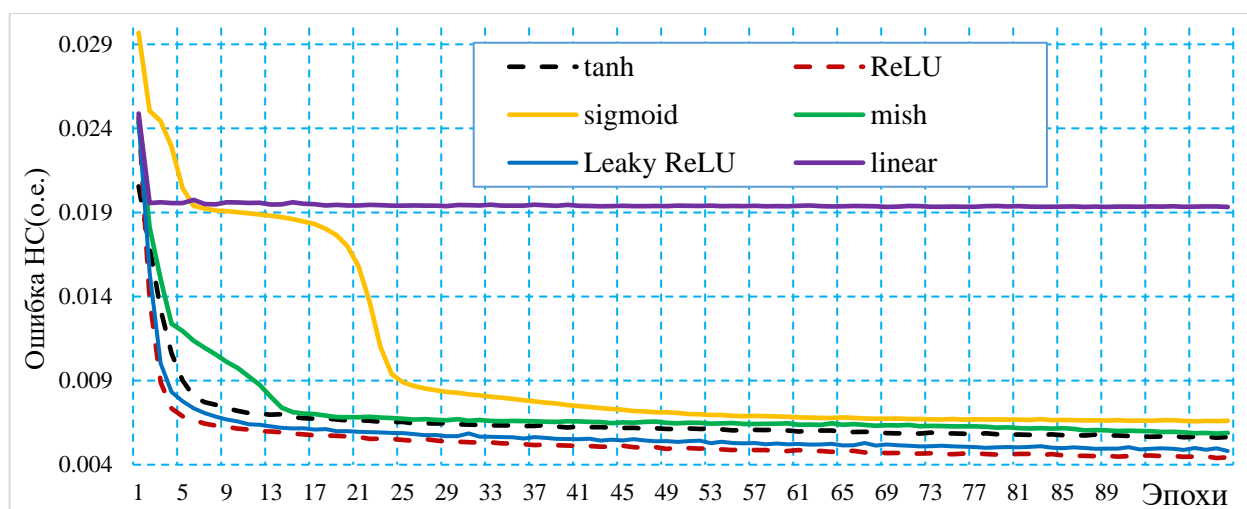


Рисунок 2.9 – Сравнение ошибки с разными функциями активации нейронов

Как следует из анализа рисунка 2.9, функция активации ReLU оказывается более эффективной в сравнении с альтернативными вариантами. Хорошие результаты также продемонстрировали функции Leaky ReLU и tanh.

Таким образом, от выбора функции активации влияет одновременно на скорость сходимости нейронной сети в процессе обучения и на точность получаемых прогнозных значений.

Определена обеспечивающая удовлетворительную точность прогнозирования комбинация параметров НС для прогнозирования ЭП: Количество скрытых слоев – 3; Распределение нейронов по слоям 40-40-30; Функция активации – ReLU; Оптимизатор – Adam; Размер пакета – 250.

2.4.2 Оценка точности прогнозирования электропотребления от размера скользящего окна

Рассмотрим примеры прогнозирования электропотребления для различных типов потребителей электроэнергии и различным характером потребления. Также рассмотрим примеры прогнозов с скользящим окном и примеры прогнозов с объединенной выборкой данных. Применялась НС с архитектурой, определенной в пар 2.5.1. На рисунке 2.10 представлены результаты тестирования НС-модели прогнозирования электропотребления, когда входные воздействия имеют циклический профиль.




Рисунок 2.10 – Сравнение фактических и прогнозных значений для циклического потребителя

На рисунке 2.11 представлены результаты тестирования НС-модели прогнозирования электропотребления, когда данные аддитивные (МАКР).




Рисунок 2.11 – Сравнение фактических и прогнозных значений для аддитивного потребителя

Расчет отклонения прогнозных значений от фактических за весь период прогнозирования производился по формуле:

$$E = \frac{\left| \sum_{i=1}^n P_{\phi} - \sum_{i=1}^n P_{\text{прог}} \right|}{\sum_{i=1}^n P_{\phi}} \cdot 100\% \quad (2.16)$$

где P_{ϕ} – фактическое потребление электроэнергии; $P_{\text{прог}}$ – прогнозные значения потребленной энергии, полученной на выходе НС.

Проведено исследование влияния скользящего окна на скорость обучения НС. В таблице 2.4 сведены усредненные значения времени, затраченного на обучение и прогнозирование ЭП.

Таблица 2.4 – Влияние скользящего окна на скорость обучения

Размер окна	3	6	12	24	36	48	72
Время, сек	80,3	80,4	81	84	86	87	90
Отклонение прогноза	45,65	16,49	9,88	3,28	10,98	9,38	75,45

Анализ таблицы 2.4 показал, что при увеличении размера окна возрастает время, необходимое на обучение. Таким образом наиболее рациональным считается размер окна равный 24, поскольку при увеличении размера окна наблюдается увеличение отклонения прогноза.

В таблице 2.5 сведены результаты прогнозирования электропотребления при помощи различных НС-моделей в т.ч. приведены значения расчета ошибки для НС, оптимизированной с помощью ГА, описанные в главе 4.

Таблица 2.5 – Сравнение ошибки прогноза с использованием СО

Тип нейросетевой модели	Алгоритм прогнозирования	Погрешность прогнозирования для типа потребителя	
		Аддитивный	Циклический
Линейная	Скользящее окно	4,987	2,516
	Без скользящего окна	12,406	0,904
Линейная с ГА	Скользящее окно	4,083	0,969
	Без скользящего окна	5,695	0,392

Учитывая опыт построения прогностических НС в MATLAB (NNtool) [43] и результаты эксперимента выявлено:

- применение скользящего окна на этом этапе позволяет повысить точность прогнозирования в среднем на 4%;
- дает возможность интеграции обученной НС и алгоритма работы в мини-компьютер при реализации без полноценного ПК.

Исследованы НС модели в задаче прогнозирования ЭП. Рассмотрены существующие решения на примере работ [64-66]. В таблице 2.6 сведены значения

ошибки прогнозирования, рассчитанные по формуле MAPE для различных типов структуры НС-моделей. Применяемую НС типа MLP (многослойный персептрон) с методом прогнозирования скользящим окном, предлагается обозначить как MLP+SW.

Таблица 2.6 – Сравнение НС прогнозных моделей

НС-модели		Ошибка прогнозирования %
1	MLR	2,18
2	RNN	5,74
3	LSTM	3,09
4	Hybrid GRU-CNN-BiLSTM	0,21
5	MLP+CO	1,71

Анализ известных исследований различных типов НС в задачах прогнозирования ЭП показал, что MLP+CO дает в среднем ошибку прогнозирования ЭП 1,71%, при этом оставаясь простой по структуре и наименее ресурсозатртой НС, вкпе с дополнительной оптимизацией структуры. Это является одним из важнейших факторов при условии развертывании прогнозной модели на миниЭВМ. Таким образом MLP+CO имеет преимущества перед, например, Hybrid GRU-CNN-BiLSTM, дающей меньшее отклонение.

Выводы по главе 2

1) Проведенное экспериментальное исследование влияния гиперпараметров нейронной сети на точность прогнозирования показало, что:

- увеличение размера пакета входных данных (BatchSize) повышает эффективность обучения, но требует больше оперативной памяти. Выбран оптимальный размер BatchSize = 250 для 8 Гб ОЗУ;

- увеличение количества слоев ускоряет обучение и повышает точность прогнозов, но требует дополнительных вычислительных мощностей. Для баланса точности и размера модели выбрано 3 слоя;

– оптимизаторы «Adam» и «RMSprop» показали наилучшие результаты для прогнозирования временных рядов благодаря адаптивному снижению скорости обучения, что улучшает усвоение сложных шаблонов и повышает точность;

– полулинейная функция активации «ReLU» показала наилучшую точность для задач прогнозирования электропотребления.

2) Анализ зависимости точности прогнозирования от профиля потребления электроэнергии выявил, что:

– качество прогноза и обучения напрямую зависит от характера изменения электропотребления (аддитивный, циклический);

– при циклическом профиле прогнозы точнее благодаря большей простоте обобщения и отсутствию необходимости учета специфических факторов.

3) Для повышения устойчивости модели к шумам и аномалиям предложено использование робастной модификации метода обратного распространения ошибки. Результаты экспериментальных исследований рассмотрены в Главе 4.

4) Для прогнозирования электропотребления у потребителей с аддитивным характером нагрузки разработан метод и алгоритм краткосрочного прогноза на основе скользящего окна. Экспериментально установлено, что использование окна размером 24 часа повышает точность прогнозирования, однако увеличение размера окна повышает время на обучение и подготовку выборки.

5) Рассмотрена возможность применения робастной модификации алгоритма обратного распространения ошибки для задачи прогнозирования электропотребления. Оценка эффективности приведена в Главе 4.

Исследование применения алгоритма прогнозирования с использованием скользящего окна выявило, что:

- наличие скользящего окна улучшает результаты прогноза в среднем на 1.2%;
- прогнозы модели, обученной на аддитивных данных, более чувствительны к изменениям структуры входных воздействий.

Таким образом, актуальной является проблема оптимизации структуры нейронной сети для достижения удовлетворительной точности.

Глава 3. НЕЙРОЭВОЛЮЦИОННЫЙ МЕТОД ДЛЯ РЕШЕНИЯ ЗАДАЧИ СИНТЕЗА АРХИТЕКТУРЫ НЕЙРОННОЙ СЕТИ

Постановка задачи. Разработать метод синтеза архитектуры НС, нацеленный на получение прогностических моделей для задач прогнозирования, использующий для оценки целевой функции точность при тестировании модели и ее размер. Цель разработки состоит в автоматизации поиска оптимальной архитектуры нейронной сети, сопоставимой или превосходящей ручной подбор параметров с учетом компромисса между точностью и размером модели

Разработка эффективных методов синтеза и оптимизации сложных информационно-управляющих систем, к которым относятся нейросетевые модели прогнозирования энергопотребления имеют особую значимость. Речь идет не просто о прогнозировании, а о создании адаптивных систем, способных реагировать на динамично меняющиеся условия. Генетический алгоритм (ГА) как адаптивный метод поиска оптимальных решений представляет собой важный инструмент системного анализа при решении задач структурного синтеза НС.

Ключевая необходимость применения ГА обусловлена следующими факторами:

1) Проблемой многокритериальной оптимизации архитектуры НС, где требуется одновременный учет таких параметров как: количество слоев, нейронов, тип функций активации, параметры обучения. ГА позволяет эффективно исследовать это многомерное пространство параметров, что соответствует задачам анализа и синтеза сложных систем в рамках специальности.

2) Необходимостью обработки больших объемов данных при обучении НС. ГА обеспечивает автоматизированный поиск оптимальных структур НС для конкретных характеристик входных данных (временных рядов энергопотребления), что относится к области обработки информации в технических системах.

3) Задачей принятия решений при проектировании прогностических моделей. ГА формализует процесс выбора оптимальной конфигурации НС как задачу принятия решения в условиях неопределенности, что соответствует одному из основных направлений специальности.

4) Требованиям адаптивности моделей к изменяющимся условиям работы энергосистем. ГА позволяет создавать НС с робастными характеристиками, способные адаптироваться к нестационарным процессам, что важно для систем управления в электроэнергетике.

5) Учитывая особенность использования генетического алгоритма как метода синтеза структуры НС-модели необходимо внести ограничение в виде компромисса точности получаемых моделей и скорости работы алгоритма

3.1 Обзор нейроэволюционных методов проектирования архитектуры

Генетические алгоритмы основываются на принципах направленного случайного поиска, имитируя эволюционные процессы, наблюдаемые в природе. В этих алгоритмах задача представляется в форме особи. Сначала создается случайная группа особей (популяция), которая представляет собой начальное поколение решений. Затем популяция подвергается воздействию операторов репродукции и мутации, что позволяет ей "пережить" одно поколение [67].

После этого происходит оценка решений и их отбор на основе функции пригодности. Особи с менее удачными параметрами исключаются, в то время как лучшие остаются, что способствует повышению точности предсказаний. Формируется новое поколение решений, и процесс повторяется. Таким образом, с каждой эпохой алгоритм находит более оптимальные решения.

В области прогнозирования генетические алгоритмы обычно не применяются напрямую, поскольку сложно определить критерии оценки прогнозов, что затрудняет отбор решений. Поэтому они чаще используются как вспомогательный инструмент, например, для обучения нейронных сетей с нестандартными активационными функциями, где применение градиентных методов становится невозможным [68].

Нейронные сети (НС) являются мощным инструментом анализа данных, в то время как генетические алгоритмы (ГА) известны как робастные методы оптимизации, благодаря способностям к адаптации. Их совместное использование

позволило бы объединить адаптивные способности ГА с аналитическими возможностями НС.

Рассматривается разработка алгоритма синтеза структуры искусственной нейронной сети с помощью генетического алгоритма.

3.1.1 Постановка задачи разработки алгоритма синтеза структуры нейросетевой модели

Постановка задачи. Синтез структуры НС состоит в представлении задачи поиска оптимальной структуры как задачи минимизации функции ошибки нейронной сети $E(N, j, Fa, O) = \min(N, j)$. Оптимизируемыми параметрами в данном случае являются: j – количество скрытых слоев; Fa – тип функции активации; O – оптимизатор функции потерь; n – количество нейронов в скрытом слое.

Для решения задачи настройки структуры нейронной сети используется генетический алгоритм. Применение ГА обусловлено тем, что генетический алгоритм обеспечивает глобальный просмотр пространства параметров, позволяя избегать локальных минимумов, а также не требует информации о градиентах [69].

Для организации генетического поиска формируется исходная популяция особей. Размер популяции обычно выбирают от 10 до 50. Некоторые исследователи считают, что он должен быть не меньше длины хромосомы [70]. Слишком большая популяция расширяет область поиска, но значительно увеличивает время выполнения алгоритма, особенно при использовании ресурсоемких фитнес-функций.

Использование генетического алгоритма для обучения нейронных сетей имеет два ключевых достоинства [71, 72]: изучение пространства поиска с помощью множества решений, что эффективно для поиска глобальных минимумов, и низкая чувствительность к росту размерности множества оптимизации.

Управляемыми параметрами в генетическом алгоритме являются длина и наполнение хромосомы, параметры операторов (кроссовера, мутации, инверсии), а также параметры выбора лучших особей и генерации популяций. Таким

образом, алгоритм позволяет настраивать практически все свои компоненты, однако существуют лишь общие рекомендации по их выбору, и конкретная реализация полностью зависит от разработчика.

3.2 Описание этапов генетического алгоритма настройки искусственной нейронной сети

Генетические алгоритмы используют для работы эволюционные принципы наследственности, изменчивости и естественного отбора. Функционирование алгоритма стартует с формирования совокупности особей, именуемой популяцией. Каждая особь представляет собой вариант решения поставленной задачи и описывается совокупностью параметров, называемых генами. Гены объединяются в единую последовательность, образуя хромосому, которая соответствует решению задачи. В рамках генетического алгоритма набор генов особи кодируется бинарной строкой, а полученная закодированная комбинация генов и есть хромосома. [73]. Рассмотрим схему функционирования генетического алгоритма в его классическом варианте:

1) Выбор исходной популяции хромосом. Для этого случайным образом генерируется конечный набор пробных решений $X^k = (x_1^k, x_2^k, \dots, x_n^k)$, $x_i^k \in X$ (первое поколение), $k = 1, 2, \dots, K$, K - размер популяции. При этом поколение состоит из K нейросетевых моделей (особей), со случайным набором хромосом (настраиваемых гиперпараметров)

2) После формирования хромосомы особи следующим этапом выступает оценка ее приспособленности, то есть степени успешности решения поставленной задачи. Для определения данного показателя строится искусственная нейронная сеть, архитектура которой задается хромосомой особи. Построенную нейросеть необходимо обучить на тренировочной выборке данных, причем в качестве обучающего алгоритма используется метод обратного распространения ошибки.

3) Оценка приспособляемости хромосом в популяции по формуле (3.1):

$$Eval(V_i) = \frac{f'_i}{\sum_{j=1}^{pop_size} f'_j}, i = 1, 2, \dots, pop_size, \quad (3.1)$$

где $f'_{i \text{ or } j} = af_{i \text{ or } j} + b$ – линейная функция масштабирования приспособленности, pop_size – размер популяции.

4) Проверка условия остановки алгоритма. Алгоритм может быть остановлен по истечении определенного времени выполнения либо после выполнения заданного количества итераций. Если условие остановки выполнено, то производится переход к завершающему этапу выбора «наилучшей» хромосомы.

5) Селекция хромосом. Состоит в выборе наиболее «приспособленных» хромосом для создания следующей популяции. Одним из наиболее популярных методов селекции является метод рулетки, при котором каждой хромосоме ch_i (для $i = 1, 2, \dots, N$) ставится в соответствие определенный сектор $v(ch_i)$, величина которого зависит от значения функции приспособляемости (3.2).

$$v(ch_i) = p_s(ch_i) \cdot 100\%, \quad (3.2)$$

где

$$p_s(ch_i) = \frac{F(ch_i)}{\sum_{j=1}^N F(ch_j)}, \quad (3.3)$$

где $F(ch_i)$ – значение функции приспособленности хромосомы ch_i , $P_s(ch_i)$ – вероятность селекции хромосомы ch_i .

Как следствие селекции хромосом, применяется оператор редукции. Данный оператор определяет какие особи продолжают участие в следующих итерациях алгоритма. Редукция используется для поддержания фактического размера популяции путём удаления самых худших особей [74].

6) Оператор мутации необходим для «выбивания» популяции из локального экстремума и препятствует преждевременной сходимости. Это достигается за счет того, что изменяется случайно выбранный ген в хромосоме.

7) Формирование новой популяции.

8) Выбор «наилучшей» хромосомы. Выбор производится при помощи метода селекции

Пример классического генетического алгоритма приведен на рисунке 3.1.

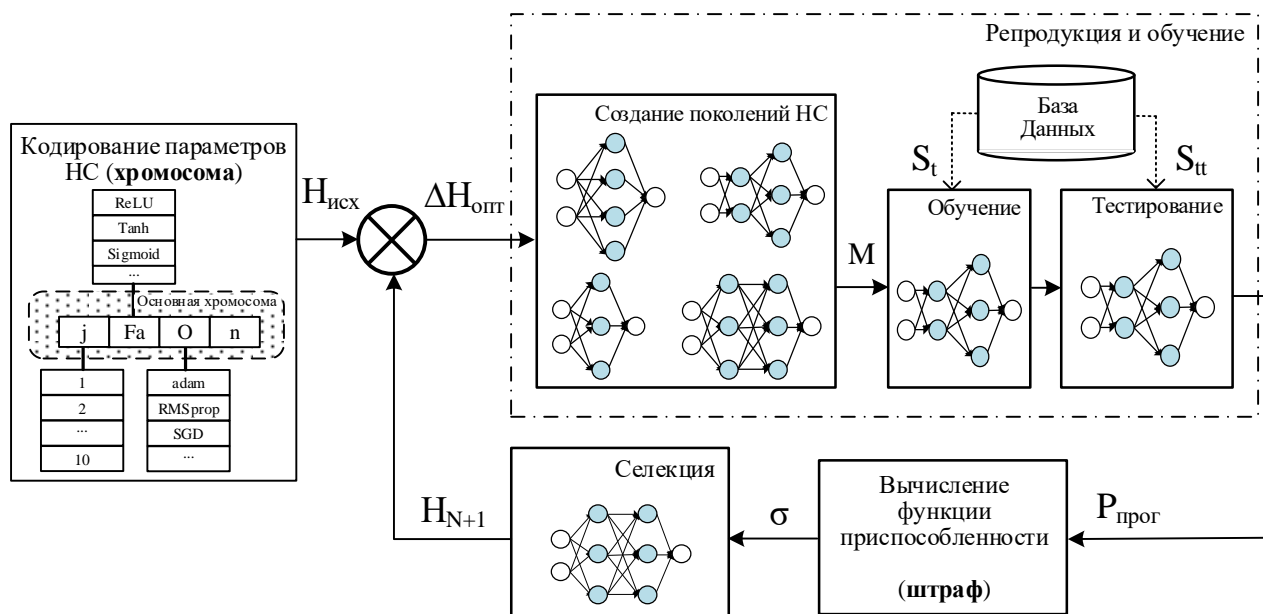


Рисунок 3.1 – Классический генетический алгоритм модели нейронной сети

3.2.1 Предлагаемое эволюционное проектирование архитектуры нейронной сети

В работе генетический алгоритм применяется для подбора архитектуры полносвязной нейронной сети прямого распространения. Исходными данными служит база данных временных рядов. Общая архитектура системы поиска оптимальной топологии представлена на рисунке 3.2.

Архитектура включает базу данных (БД), которая сохраняет данные о предыдущих поисках для сокращения времени на подбор модели при новых запусках.

Блок оценки особей производит их оценку и отбор для следующего поколения (например, методом рулетки или турнирным отбором) и функционирует независимо от других компонентов системы. Блок генерации особей работает на этапе формирования как начальной, так и последующих популяций.

Обучение нейронных сетей происходит в отдельном блоке, который получает хромосому с параметрами сети и рекомендации по обучению из БД, а на выходе выдает матрицы весов синаптических связей.

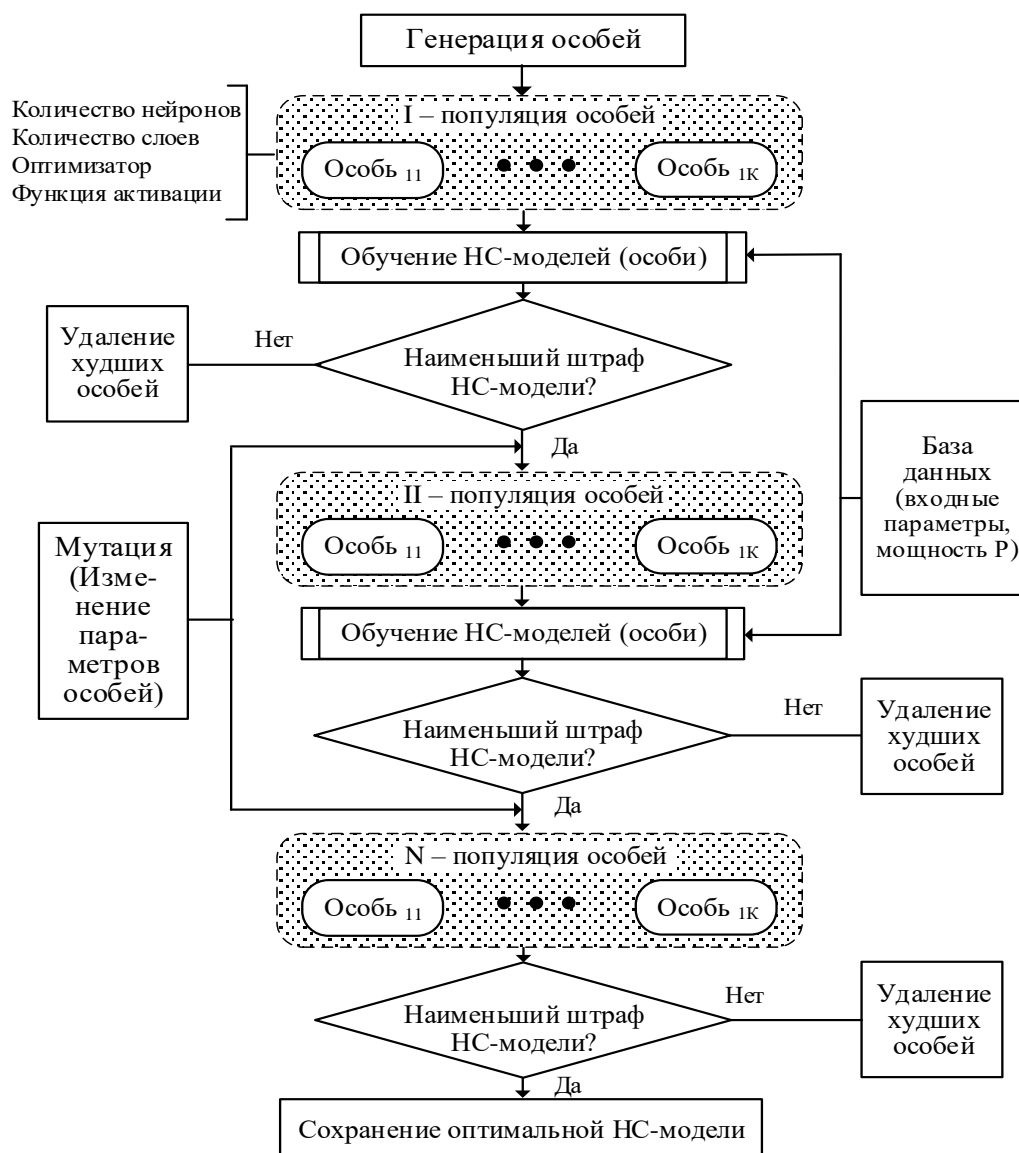


Рисунок 3.2 – Общая архитектура топологии поиска нейронной сети

В качестве целевой функции можно выбирать из нескольких вариантов формул, оценивающих обучение нейронной сети. По входам и выходам выбрана (3.4):

$$GF = \sum_{j=1}^m \frac{\sum_{i=1}^k |y_i^j - \hat{y}_i^j|}{k \cdot m} \quad (3.4)$$

где k - количество выходов нейронной сети; m – количество примеров в валидационной выборке; y - желательное значение выхода; \hat{y} - реальное значение выхода.

Традиционно в алгоритме используется механизм рекомбинации (скрещивания). В работе предлагается изменение процедуры получения архитектуры НС-мо-

дели, при которой новое поколение особей создается только путем мутации лучшей особи. Что позволило сократить объем используемых ресурсов для обучения особей (НС-моделей).

Применение метода обратного распространения ошибки при синтезе структуры нейросети способом ГА. К числу типовых задач, решаемых посредством прямого обучения, относятся аппроксимация неизвестной функции по имеющемуся набору данных, а также идентификация динамического объекта. Для таких задач известны входные сигналы и соответствующие им эталонные реакции, то есть имеется тренировочный набор шаблонов.

В рамках прямого контролируемого обучения для многослойных полносвязных НС прямого распространения наиболее известным и широко применяемым является алгоритм обратного распространения ошибки.

1) **Сбор статистических данных и признаков.** Сбор информации проводится как из открытых источников (например, метеоданные или производственный календарь) так и после накопления баз данных путем снятия значений со счетчиков электроэнергии, метеостанций. Влияющие параметры, такие как: потребленная мощность ($P_{\text{потр}}, Q_{\text{потр}}$), метеофакторы, включающие информацию об осадках, ветровых значениях и среднесуточной температуры (R, W, T); дате и времени (D, M, Y, t); социальных данных (статус дня) (S)..

2) **Формирование выборки данных** – Применение рассмотренных в главе 1 методов предобработки.

3) **Создание поколения НС.** Генерация популяций НС-моделей для каждого поколения обучения производится при помощи генетического алгоритма. Реализация данного алгоритма в решении задачи создания прогностической НС для прогнозирования ЭП приведена в разделе 3.3.1. Хромосома, описывающая настраиваемые параметры НА содержит следующие гены:

- Количество слоев в НС (j);
- Количество нейронов в слое (i);

- Функция активации нейронов для каждого слоя (Fa);
- Оптимизатор, используемый при обучении (O).

4) **Цикл обучения.** Обучения особей (НС-моделей) выполняется при помощи широко известного алгоритма обратного распространения ошибки. нейронных сетей методом обратного распространения ошибки с использованием генетического алгоритма. Цикл включает в себя этапы как обучения каждой особи, так оценку приспособленности полученной модели на тестовой выборке и последующую селекцию лучшей модели:

В методе рулетки, применяемой в данной задаче, особи отбираются с помощью «запусков» рулетки, где N – размер популяции. Колесо рулетки содержит по одному сектору для каждого члена популяции. Размер i -го сектора пропорционален вероятности попадания в новую популяцию $P(i)$, вычисляемой по формуле:

$$P(i) = \frac{f(i)}{\sum_{j=1}^N f(j)}, \quad (3.5)$$

где $f(i)$ – пригодность i -й особи.

Ожидаемое число копий i -ой хромосомы после оператора рулетки определяются по формуле $N_i = P(i)N$.

5) Конечную оценку лучшей модели по завершению работы ГА выполняет оператор. Если модель удовлетворяет требованиям по точности работы с конкретным потребителем, то производится дообучение НС с большим количеством эпох. В противном случае алгоритм запускается заново, но начинает работу с НС-моделью, полученной после последнего запуска ГА.

Суть применения ГА позволяет автоматизировать времязатратный процесс подбора наиболее подходящих параметров для решения конкретной прикладной задачи (рисунок 3.3).

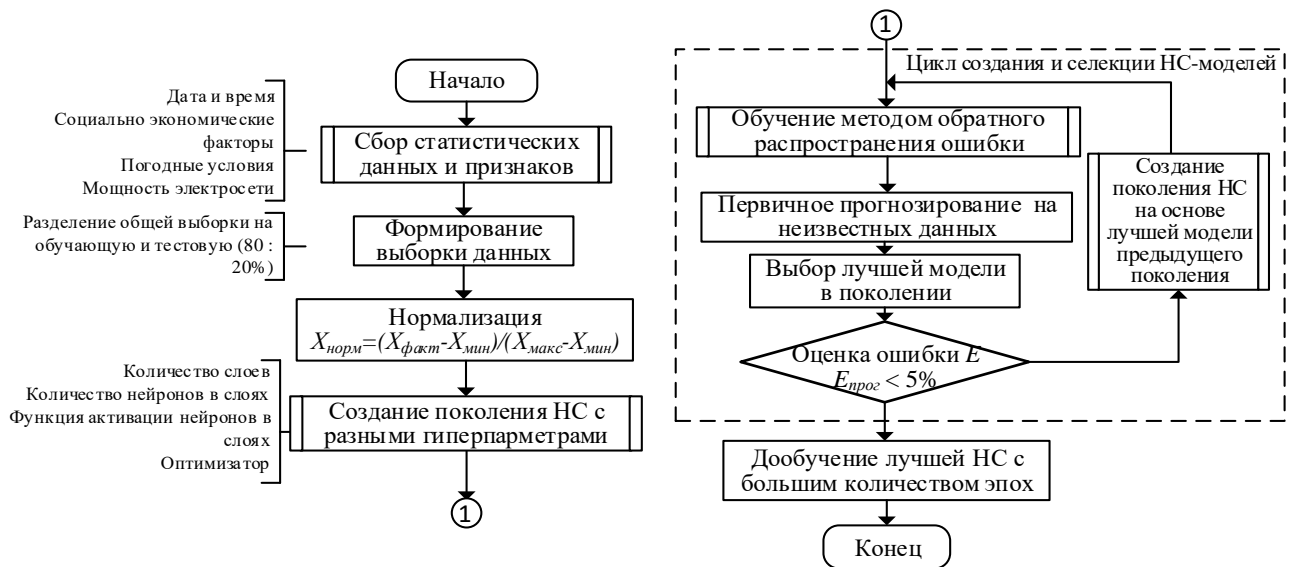


Рисунок 3.3 – Блок схема генетического алгоритма прогнозирования режимов энергопотребления

Известна проблема с «застреванием» нейронной сети в локальных минимумах, с которой позволяет бороться также оператор скрещивания, в предлагаемом способе создания НС-модели без оператора скрещивания и прогнозирования не наблюдалась.

Таким образом, модификация гибридного алгоритма оптимизации НС-модели (рисунок 3.3) заключается в:

- введению «первичного» тестирования полученных особей, обученных на небольшом количестве эпох = 50, позволяющего быстро оценить архитектуру НС на малом числе эпох;
- обучении лучшей особи до сходимости на полном датасете с большим количеством эпох = 500.

Поскольку окончательное обучение происходит только для лучшей архитектуры, снижается вероятность переобучения промежуточных моделей и дает возможность ускорить процесс подбора гиперпараметров, так как обучение на малом количестве эпох позволяет оценить качество восприятия информации, создаваемой НС-модели.

3.3 Разработка гибридного алгоритма прогнозирования аддитивного потребителя для системы поддержки принятия решений

Гибридная система представляет собой комплекс, интегрирующий две или более разнородные подсистемы. Концепция гибридных алгоритмов базируется на интеграции генетического алгоритма со специализированным методом поиска, релевантным для конкретной проблемы. На каждом этапе эволюции (в каждом поколении) каждая вновь созданная особь подвергается дополнительной оптимизации с помощью данного метода, и лишь затем осуществляются стандартные для генетического алгоритма операции.

Данный принцип развития носит название ламарковой эволюции. В ее рамках индивид приобретает новые навыки в процессе обучения, которые затем кодируются в его геноме для передачи последующим поколениям. Несмотря на то, что подобный подход может ограничивать способность алгоритма к исследованию пространства решений через отбор гиперплоскостей, на практике гибридные алгоритмы демонстрируют высокую эффективность. Это объясняется значительным повышением вероятности того, что хотя бы одна из особей достигнет области глобального оптимума и после локальной оптимизации будет идентифицирована в качестве итогового решения [75].

Предлагается использование генетического алгоритма в связке с нейросетевой моделью. ГА используется для поиска параметров нейронной сети. [76, 77]

3.3.1 Реализация функций гибридного алгоритма обучения нейросети в Python

Листинг:

```
def ChooseOpt(number):
    if isinstance(number, (int)):
        number = number % 11
        return optimizers[number]
    else:
        return optimizers.index(number)

def ChooseActFunc(number):
    if isinstance(number, (int)):
        number = number % 18
        return activation_function[number]
```

```

else:
    return activation_function.index(number)

```

Функция, ChooseOpt получая значения integer, возвращает название оптимизатора из списка. Функция предварительно получает остаток от деления полученного числа на 11 (общее количество оптимизаторов). Если же функция получает иной тип значений, то возвращает из списка порядковый номер (индекс) оптимизатора из списка. Функция ChooseActFunc работает аналогично для функций активации

Создание поколения нейросетей. Выполняется при помощи функции Create_Model,0 которая создает модель НС по параметрам, заданным в массивах гиперпараметров. Функция принимает на вход номер модели в поколении, и возвращает созданную модель, запускает цикл, который поочередно добавляет слои в нейронную сеть с параметрами, которые записаны в массивах. Выходной слой имеет 1 нейрон на выходе ($P_{\text{прогн}}$)

Листинг:

```

def Create_Model(num):
    model = tf.keras.Sequential()
    for i in range(MaxSize):
        if i != MaxSize-1:
            if Networks_Structure[num][i] > 0:
                model.add(keras.layers.Dense(units=Networks_Structure[num][i],
                    activation=ChooseActFunc(Networks_Functions[num][i]),
                    name=(str(ChooseActFunc(Networks_Functions[num][i])) + str(i))))
            else:
                model.add(keras.layers.Dense(units = 1, activation=ChooseActFunc(Networks_Functions[num][i]),
                    name=(str(ChooseActFunc(Networks_Functions[num][i])) + str(i))))
    return model

```

Расчета штрафа НС выполняется функцией Error_Calculate.

Листинг:

```

def Error_Calculate(num, NNP, TestL):
    err = 0
    for i in range(len(NNP[0])):
        if TestL[i][0] > 0:
            err += abs(((NNP[0][i]-TestL[i][0])/TestL[i][0]))
        else:
            err += 1
    err = (pow(((err/len(NNP[0]))*100), 5))/1000
    Neurons_Number = 0
    for k in range(len(Networks_Structure[num])):
        Neurons_Number += Networks_Structure[num][k]
    Neurons_Number = pow(Neurons_Number, 0.5)
    err *= Neurons_Number
    if math.isnan(err) == False:

```

```

err = round(err)
else:
err = 1000000000
return err

```

На вход функции подается порядковый номер НС в поколении, прогноз НС и фактические данные (тестовая выборка).

В функции вычисляется сумма модулей абсолютных отклонений прогнозов от фактических данных. Далее сумма пересчитывается по следующей формуле:

$$E = \frac{\left(\frac{D}{P_{num}} \cdot 100\% \right)}{1000},$$

где D – это сумма модулей абсолютных отклонений, P_{num} – это количество данных, E – это полученная ошибка.

Ошибка возводится в 5 степень, чтобы увеличить ее значимость в дальнейших расчетах. Далее в функции рассчитывается общее количество нейронов в НС после из общего количества нейронов берется квадратный корень, чтобы уменьшить значимость этого значения в дальнейших расчетах. Далее рассчитанная ошибка и корень из общего количества нейронов перемножаются, формируя штраф.

Таким образом штраф НС формирует 2 параметра, размер НС (кол-во слоев – j , кол-во нейронов – n) и ее ошибка (E). Ошибка находится в приоритете, но и с большим размером, НС будет иметь больший штраф. Далее проводится проверка, на тот случай если штраф будет иметь значение “nan”, это может произойти из-за “взрыва весов НС”, в таком случае прогнозы НС не будут иметь какой-либо смысл, и ей устанавливается штраф по умолчанию равный 1 миллиарду. Если же значение не равно “nan”, то оно просто округляется. Функция возвращает рассчитанный штраф.

Функция `Save_Best_Model` перемещает в отдельный файл лучшую модель и удаляет все оставшиеся.

Листинг:

```

def Save_Best_Model():
    Best_Network_ID = Networks_FF.index(min(Networks_FF))
    Best_Network_Path = str(str(Networks_Optimizers[Best_Network_ID]) + 'Opt' +
str
(Networks_FF[Best_Network_ID]) + '.keras')

```

```

os.replace('Models' + '/' + Best_Network_Path, 'BestModel' + '/' + Best_Netw
ork_Path)
folder = 'Models'
for filename in os.listdir(folder):
    file_path = os.path.join(folder, filename)
    try:
        if os.path.isfile(file_path) or os.path.islink(file_path):
            os.unlink(file_path)
        elif os.path.isdir(file_path):
            shutil.rmtree(file_path)
    except Exception as e:
        print('Failed to delete %s. Reason: %s' % (file_path, e))

```

В качестве примера работы функции оценки приспособленности (удаления лишних моделей) на рисунке 3.4 приведен график ошибок, где n – количество созданных особей. Расчет ошибок проводился после первичного тестирования в ходе работы ГА. График представляет зависимость расчета ошибки первичного тестирования от порядка создания особей.




Рисунок 3.4 – Оценка приспособленности особей

Из приведенного графика видно, что в ходе создания новых особей в процессе мутации появляются особи, обладающие низкой приспособленностью (высокий штраф). Это является результатом неподходящими гиперпараметрами или не восприятием НС-моделью данных из обучающей выборки. Как следствие данные модели удаляются. Если в новом поколении есть модель, имеющая большую приспособленность, чем в прошлом, то она сохраняется и на ее основе создается новое поколение. В противном случае за основу берется лучшая сохраненная особь из предыдущего поколения.

На рисунок 3.5 приведен график, показывающий снижение ошибки в процессе работы ГА. При построении график использовались значения штрафов как

лучших моделей, так и не прошедших селекцию. Они представлены в порядке убывания значения штрафа.




Рисунок 3.5 – Снижение штрафа особей

Приведена реализация, процесса создания новых гиперпараметров НС в блоке кода, реализующего механизм мутации гиперпараметров на основе случайных изменений лучшей модели.

```

for i in range(1, int(round(Generation_Size*0.7))):
    New_Arr = []
    for i in range(MaxSize):
        if random.randint(0,1) != 0:
            if len(Networks_Structure[0]) > 1:
                New_Arr.append(Networks_Structure[0][i])
            else:
                New_Arr.append(0)
        else:
            if len(Networks_Structure[0]) > 1:
                New_Arr.append(Networks_Structure[0][i]+random.randint(-20,20))
            else:
                New_Arr.append(random.randint(0, 30))
    Networks_Structure.append(New_Arr)

    New_Arr = []
    for i in range(MaxSize):
        if random.randint(0,1) != 0:
            if len(Networks_Functions[0]) > 1:
                New_Arr.append(Networks_Functions[0][i])
            else:
                New_Arr.append(random.randint(0, 17))
        else:
            New_Arr.append(random.randint(0, 17))
    Networks_Functions.append(New_Arr)

    if random.randint(0, 1) == 0:
        Networks_Optimizers.append(random.randint(0, 10))
    else:
        Networks_Optimizers.append(Networks_Optimizers[0])

```

Вероятность мутации выбирают небольшой от 0,01 до 0,2. В данной работе вероятность мутации равна 0,2. Операция мутации выполняется в следующей последовательности:

- с вероятностью P осуществляется возможность операции мутации;
- случайным образом определяется ген, подлежащий мутации;
- с вероятностью 50% выбранный ген заменяется на новое значение.

Приведен листинг реализации процесса обучения и последующего тестирования моделей. Обученные и протестированные модели сохраняются с кодовым номером, который состоит из оптимизатора используемого в процессе обучения и штрафа модели. Прогноз может производиться как с реализацией метода скользящего окна, так и без. По окончании каждого шага цикла, очищается тензор. После цикла сохраняется лучшая модель и очищаются массивы с гиперпараметрами.

```
for NW in range(1, Generation_Size):
    model = Create_Model(NW)
    model.compile(optimizer=ChooseOpt(Networks_Optimizers[NW]), # Оптимизатор
                  loss='mean_squared_error')
    if Sliding_Window == True:
        train_history = model.fit(trd_W, tri, epochs=EHS, batch_size=Batch_Size)
    else:
        train_history = model.fit(trd, tri, epochs=EHS, batch_size=Batch_Size)
    if Sliding_Window == True:
        predictions = []
        for i in range(len(new_data_W)):
            predictions.append(model.predict(np.array([new_data_W[i], ])) [0] [0])
            if i < len(new_data_W)-1:
                new_data_W[i+1][8] = predictions[i]
        pred = pd.DataFrame(predictions)
    else:
        pred = pd.DataFrame(model.predict(np.array(new_data, dtype=float)))
    error = Error_Calculate(NW, pred, test_labels)
    Networks_FF.append(error)
    model.save('Models' + '/' + str(Networks_Optimizers[NW]) + 'Opt'+str(error)
              + '.keras')
    print(Steps + 1, '/', MEHS, '', NW + 1, '/', Generation_Size)
    Clear_Session()
```

Важной особенностью является внедрение в разработанный алгоритм метода скользящего окна, позволяющего подавать в автоматизированном режиме на вход НС значения о потребленной мощности за необходимый период времени, предшествующий необходимому моменту прогноза. Применение данного метода позволит:

- сократить время подбора гиперпараметров и обучения до 8 часов;
- добиться увеличения точности прогнозирования электропотребления для потребителей с аддитивным характером;

• автоматизация процесса обучения позволяет не отвлекаться на постоянный контроль работы алгоритма. Освобождается рабочее время оператора.

3.3.2 Анализ и синтез структур нейросетевых моделей с помощью генетического алгоритма

После завершения работы ГА подбора параметров и дообучения НС-модели можно производить прогнозирование.

Логика выполнения:

- 1) Импорт необходимых библиотек;
- 2) Создание датафрейма для тестовых данных;
- 3) Загрузка лучшей модели полученной после работы ГА;
- 4) Вывод структуры НС-модели;
- 5) Прогнозирование;
- 6) Сохранение прогноза в файл Excel (Файл перезаписывается и дополняется новыми прогнозами).

Параметры полученных при помощи разработанного ГА НС-моделей представлены в таблицах 3.1 – 3.4. Входной и выходной слой не приводятся в таблицах (описывающих структуру НС-модели).

Структура НС-модели, при подборе параметров при помощи ГА для потребителя типа с аддитивным профилем ЭП приведена в таблица 3.1.

Таблица 3.1 – Структура полученной НС-модели при помощи ГА

Номер слоя	Функция активации	Количество нейронов	Количество связей
1	Linear	10	90
2	Leaky_ReLU	28	308
3	SeLU	28	338
4	Linear	9	261
5	Softsign	30	300
6	Leaky_ReLU	26	806
7	SeLU	16	432
8	Linear	1	17

Структура НС-модели, при подборе параметров при помощи ГА для потребителя с аддитивно-сезонным профилем ЭП приведена в таблица 3.2.

Таблица 3.2 – Структура полученной НС-модели при помощи ГА

Номер слоя	Функция активации	Количество нейронов	Количество связей
1	Exponential	11	165
2	ReLU	3	63
3	Softsign	12	48
4	ReLU	26	338
5	Linear	16	432
6	SeLU	27	459
7	SeLU	11	308
8	ReLU	5	60
9	ReLU	23	138
10	Sigmoid	1	24
Оптимизатор		Adamax	

Структура НС-модели, при подборе параметров при помощи ГА для потребителя с аддитивно-случайным профилем ЭП приведена в табл. 3.3.

Таблица 3.3 – Структура полученной НС-модели при помощи ГА

Номер слоя	Функция активации	Количество нейронов	Количество связей
1	ReLU	26	234
2	SeLU	30	810
3	Leaky_ReLU	22	682
4	SiLU	5	115
5	SiLU	16	96
6	Softplus	18	306
7	SeLU	21	399
8	Hard_Sigmoid	30	660
9	Exponential	23	713
10	ReLU	1	24
Оптимизатор		Adam	

Структура НС-модели, при подборе параметров при помощи ГА для потребителя с циклическим профилем ЭП приведена в таблица 3.4.

Таблица 3.4 – Структура полученной НС-модели при помощи ГА

Номер слоя	Функция активации	Количество нейронов	Количество связей
1	Leaky_ReLU	28	252
2	Tanh	10	290
3	eLU	28	308
4	eLU	9	216
5	Hard_Sigmoid	1	10
Оптимизатор		RMSprop	

Таким образом, анализ структур НС-моделей, подобранных при помощи разработанного алгоритма показал, что:

- для потребителей с профилем аддитивного типа создается НС-модель максимально доступного размера. N -слоев ≤ 10 (таблица 3.1);
- для потребителей с аддитивно-сезонным (таблица 3.2) профилем электропотребления структура НС-модели подбирается с меньшим количеством слоев, чем для аддитивно-случайного профиля;
- для потребителей с аддитивно-случайным профилем (таблица 3.3) используется большее количество нейронов на слой, что позволяет добиться приемлемой точности при отсутствии данных о некоторых причинах изменения потребления ЭЭ;
- для потребителей с циклическим профилем (таблица 3.4) подбирается структура сети заметно меньшего размера, чем для аддитивных профилей потребления. Подобрано 5- слоев, при заданных условиях N -слоев ≤ 10 . Количество нейронов на слой и количество связей также меньше, чем для профилей аддитивного типа.

Выводы по главе 3

1) Сформулирована задача оптимизации структуры нейросетевой модели прогнозирования электропотребления. Определены преимущества использования генетического алгоритма для подбора гиперпараметров, уточнена архитектура поиска топологии сети и получена целевая функция для оценки качества обучения модели.

2) На основе анализа методов оптимизации архитектуры нейронных сетей выбран генетический алгоритм, обладающий следующими достоинствами: многопозиционный поиск решения, использование целевой функции без производных, простота реализации и совместимость с другими алгоритмами. Определена структура хромосомы, кодирующая параметры сети: количество скрытых слоев, тип функции активации, оптимизатор и количество нейронов в слоях.

3) Установлено, что совместное использование эволюционных алгоритмов и нейронных сетей позволяет параллельно решать задачи синтеза структуры сети и её обучения.

4) Предложен модифицированный генетический алгоритм для оптимизации архитектуры нейронной сети, сочетающий быструю оценку особей на малом числе эпох с последующим дообучением лучшей конфигурации. Метод сокращает вычислительные затраты за счет эвристического отбора перспективных архитектур.

5) Разработан скрипт на Python, реализующий эволюционный метод подбора гиперпараметров без оператора скрещивания. Создание поколений осуществляется мутацией лучшей особи, а в качестве функции приспособленности используется оценка ошибки прогнозирования после первичного обучения.

6) Экспериментально выявлено, что разработанный алгоритм позволяет сократить время подбора гиперпараметров до 8 часов, повысить точность прогнозирования для потребителей с аддитивным характером нагрузки и автоматизировать процесс обучения. Исследование показало, что для разных профилей потребления алгоритм подбирает сети соответствующей сложности: максимального размера для аддитивного типа, меньшей сложности для аддитивно-сезонного и большего количества нейронов для аддитивно-случайного профиля. Для циклического профиля выбирается структура заметно меньшего размера.

Глава 4. ОЦЕНКА ЭФФЕКТИВНОСТИ НЕЙРОСЕТЕВОЙ МОДЕЛИ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ

Постановка задачи. Оценить эффективность адаптированных и разработанных методов и алгоритмов применительно к прогнозированию нагрузки аддитивных потребителей для подтверждения работоспособности предлагаемых методов повышения точности прогнозирования. В качестве метрики качества прогнозных значений использовать отклонение типа MAPE, как наиболее наглядное. Экспериментально подтвердить снижение ошибок прогнозирования или получить сопоставимые с существующими методами значения.

Проблема оценки эффективности нейросетевой модели в задачах прогнозирования электропотребления заключается в учёте множества факторов, влияющих на колебания энергопотребления, и минимизации ошибок прогнозирования. Это требует анализа методов, данных, параметров модели и ошибок, возникающих при её использовании. Существующие методы прогнозирования электропотребления позволяют эффективно работать только с потребителями с циклическим профилем (пар 1.2).

Опираясь на анализ результатов работы, описанные в главе 1 и 2, а именно проблему создания прогнозной модели и метода для потребителей с аддитивным профилем потребления, т.е. не имеющем повторяемости данных на одинаковых по длительности участках времени.

По этой причине встает задача в разработке метода прогнозирования, позволяющего корректно моделировать нагрузку потребителей, обладающими аддитивным профилем потребления, для которых существующие методы не подходят, а также оптимизировать работу классической сети прямого распространения для работы с предлагаемым методом на основе авторегрессии.

При выполнении исследования введены следующие ограничения:

- Период исследования ограничен валидационной выборкой размером в 1 год почасовых замеров потребления ЭЭ.

- Максимальная погрешность ограничена 3 процентами согласно Приказа Министерства энергетики Российской Федерации от 11 февраля 2019 г. №91 «Об

утверждении требований к прогнозированию потребления и формированию балансов электрической энергии и мощности энергосистемы на календарный год и периоды в пределах года».

– Ограничение при расчете отклонения прогноза заключается в усреднении результатов работы НС после нескольких запусков так как обучение одной и той же модели с одинаковыми данными и обработкой может дать разные результаты из-за инициализации весов и перемешивания данных.

4.1 Оценка точности нейросетевого прогнозирования с подбором гиперпараметров вручную для разных типов потребителей

В исследовании использованы данные электропотребления различными типами потребителей электроэнергии с различным характером потребления (циклический, аддитивный). Применяется обработка данных методом скользящего окна.

Основная гипотеза данного исследования заключается в возможности повысить точность краткосрочного прогнозирования электропотребления за счет использования алгоритма скользящего окна.

Выборка содержит записи с шагом в 1 час за 3,5 года (2021–2024 гг.). Таким образом, выборка содержит 30660 строк и 9 столбцов.

На рисунке 4.1 представлены результаты тестирования НС-модели прогнозирования электропотребления, когда входные воздействия, изменяются по какой-либо закономерности.




Рисунок 4.1 – Тестирование НС-модели прогнозирования.

Специальная категория потребителей электрической энергии, которая относится к особым объектам, требующим особого подхода к обеспечению электроснабжения, включает в себя объекты, которые имеют особую важность с точки зрения национальной безопасности, обороны, экологии или жизнеобеспечения населения. Это крупные объекты инфраструктуры (например, аэропорты). Здесь требования к надежности электроснабжения, безопасности и эффективности системы электроснабжения будут особенно строгими, они основаны на специальных регламентах и стандартах. На рисунке 4.2 результаты тестирования НС-модели прогнозирования электропотребления, когда данные об энергопотреблении имеют аддитивный характер. Результаты расчета средней абсолютной погрешности прогноза НС в зависимости от данных приведены в таблице 4.1.

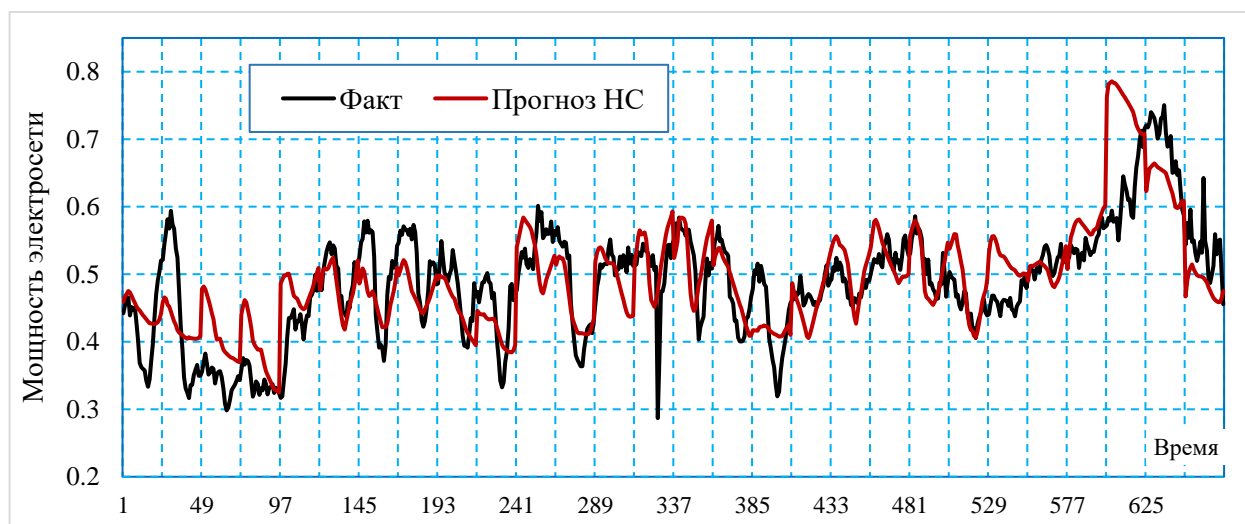


Рисунок 4.2 – Сравнение фактических и прогнозных данных энергопотребления

Таблица – 4.1 Погрешности прогноза НС в зависимости от данных

Характер потребителя электроэнергии	Погрешность прогноза НС-модели, %
Аддитивный	5,695
Циклический	0,392

Таким образом, анализ полученных зависимостей (рисунки 4.1, 4.2) и результаты погрешности (таблица 4.1) показал, что:

– от характера изменения данных зависит, то насколько хорошо НС будет составлять прогнозы;

– для данных, которые изменяются по явной закономерности, прогнозы более точны, чем для аддитивных данных.

Дальнейшие прогнозы будут производиться на двух выборках данных, чтобы можно было более явно наблюдать влияние изменений входных воздействий.

4.2 Оценка точности прогнозирования при синтезе структуры нейросетей с помощью генетического алгоритма для разных типов потребителей

В данном параграфе рассматриваются примеры прогнозирования нейронных сетей гиперпараметры которых подбирались с помощью ГА, а веса обновлялись с помощью метода обратного распространения ошибки.

Рассмотрим пример, когда входные воздействия, изменяются по какой-либо закономерности.

На рисунке 4.3 представлено сравнение результатов НС прогнозирования с фактическими данными циклического потребителя. Гиперпараметры нейросети подбирались с помощью ГА.

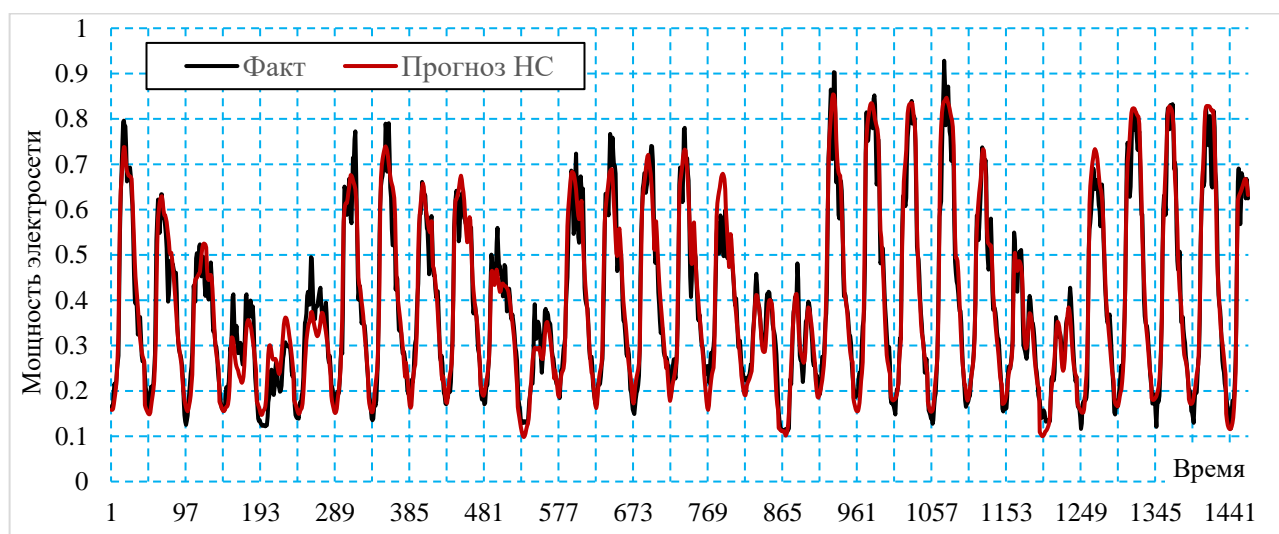


Рисунок 4.3 – Тестирование НС-модели прогнозирования

На рисунке 4.4 представлено сравнение прогнозов НС с данными потребителя с аддитивным профилем ЭП, гиперпараметры которой подбирались с помощью ГА.




Рисунок 4.4 – Тестирование НС-модели прогнозирования

Усредненные результаты расчета погрешностей НС прогнозирования в зависимости от характера потребителя электроэнергии, сведены в таблицу 4.2.

Таблица 4.2 – Погрешность НС-модели прогноза.

Характер потребителя электроэнергии	Погрешность прогноза НС, %
Аддитивный	1,15
Циклический	0,194

Таким образом, анализ полученных зависимостей (рисунки 4.3, 4.4) и результаты расчета погрешности (таблица 4.1, 4.2) приходим к выводу, что:

- 1) применение генетического алгоритма позволяет повысить точность прогнозирования в среднем на 3%;
- 2) подтверждено, что для данных, которые изменяются по явной закономерности, прогнозы намного точнее, чем для аддитивных данных.

4.3 Экспериментальная оценка совокупности методов повышения точности прогнозирования электропотребления

При использовании ГА и скользящего окна. Рассмотрены различные способы подбора гиперпараметров (вручную и посредством ГА), а также применение скользящего окна. Ошибка прогнозирования электропотребления на месяц, для нейросетей созданных разными способами, для различных методов при-

ведена в таблице 4.3. На рисунках 4.5.1-4.5.2 представлены профили фактического электропотребления с циклическим профилем (ЮЗЭС) и графики НС-прогноза, на разные промежутки времени. НС прогнозы электропотребления составлены без скользящего окна.




Рисунок 4.5.1 – Тестирование генетической НС-модели прогнозирования на неделю без скользящего окна




Рисунок 4.5.2 – Тестирование генетической НС-модели прогнозирования на день без скользящего окна

Таблица 4.3 – Сравнение точности прогнозов НС, созданных разными способами

Способ подбора гиперпараметров	Погрешность прогноза НС, %			
	Без скользящего окна		С скользящим окном	
	Аддитивный	Циклический	Аддитивный	Циклический
Вручную	4,987	0,904	12,406	2,516
Генетический алгоритм	5,695	0,392	4,083	0,969

Обобщение результатов вычисления погрешности (таблица 4.4) совместно с практическим опытом, приобретенным в ходе построения разнообразных нейросетевых архитектур, позволяет сделать ряд заключений. Использование генетического алгоритма заметно облегчает процедуру нахождения наилучших конфигураций нейронных сетей. Модели, оптимизированные с помощью генетического алгоритма, обеспечивают прогнозы, точность которых в среднем выше на 2,419%. Процесс подбора гиперпараметров при применении генетического алгоритма не требует вмешательства оператора — все необходимые действия алгоритм выполняет самостоятельно. Кроме того, генетический алгоритм многократно ускоряет процесс настройки гиперпараметров, сокращая его длительность вплоть до шести раз по сравнению с ручным перебором. Отдельно стоит отметить, что, хотя применение скользящего окна приводит к незначительному росту ошибки прогнозирования, его использование позволяет получить прогнозный профиль электропотребления, максимально приближенный к реальному.

При добавлении модификации алгоритма обучения. Исследовано влияние на погрешность прогнозирования ЭП применения робастных функций потерь вместо классической MSE.

Тестирование производилось двумя способами создания НС-модели:

- 1) Создание НС фиксированной структуры (подобранные экспериментально).
- 2) Создание НС при помощи разработанного генетического алгоритма подбора параметров (см. Главу 3).

Исследовались потребители со следующими профилями ЭП: Циклический; 2) Аддитивный; 3) Аддитивно-сезонный; 4) Аддитивно случайный.

Графики сравнение фактического электропотребления и спрогнозированного нейросетью, с использованием функций потерь MSE, Хьюбера и Коши приведены на рисунке 4.6

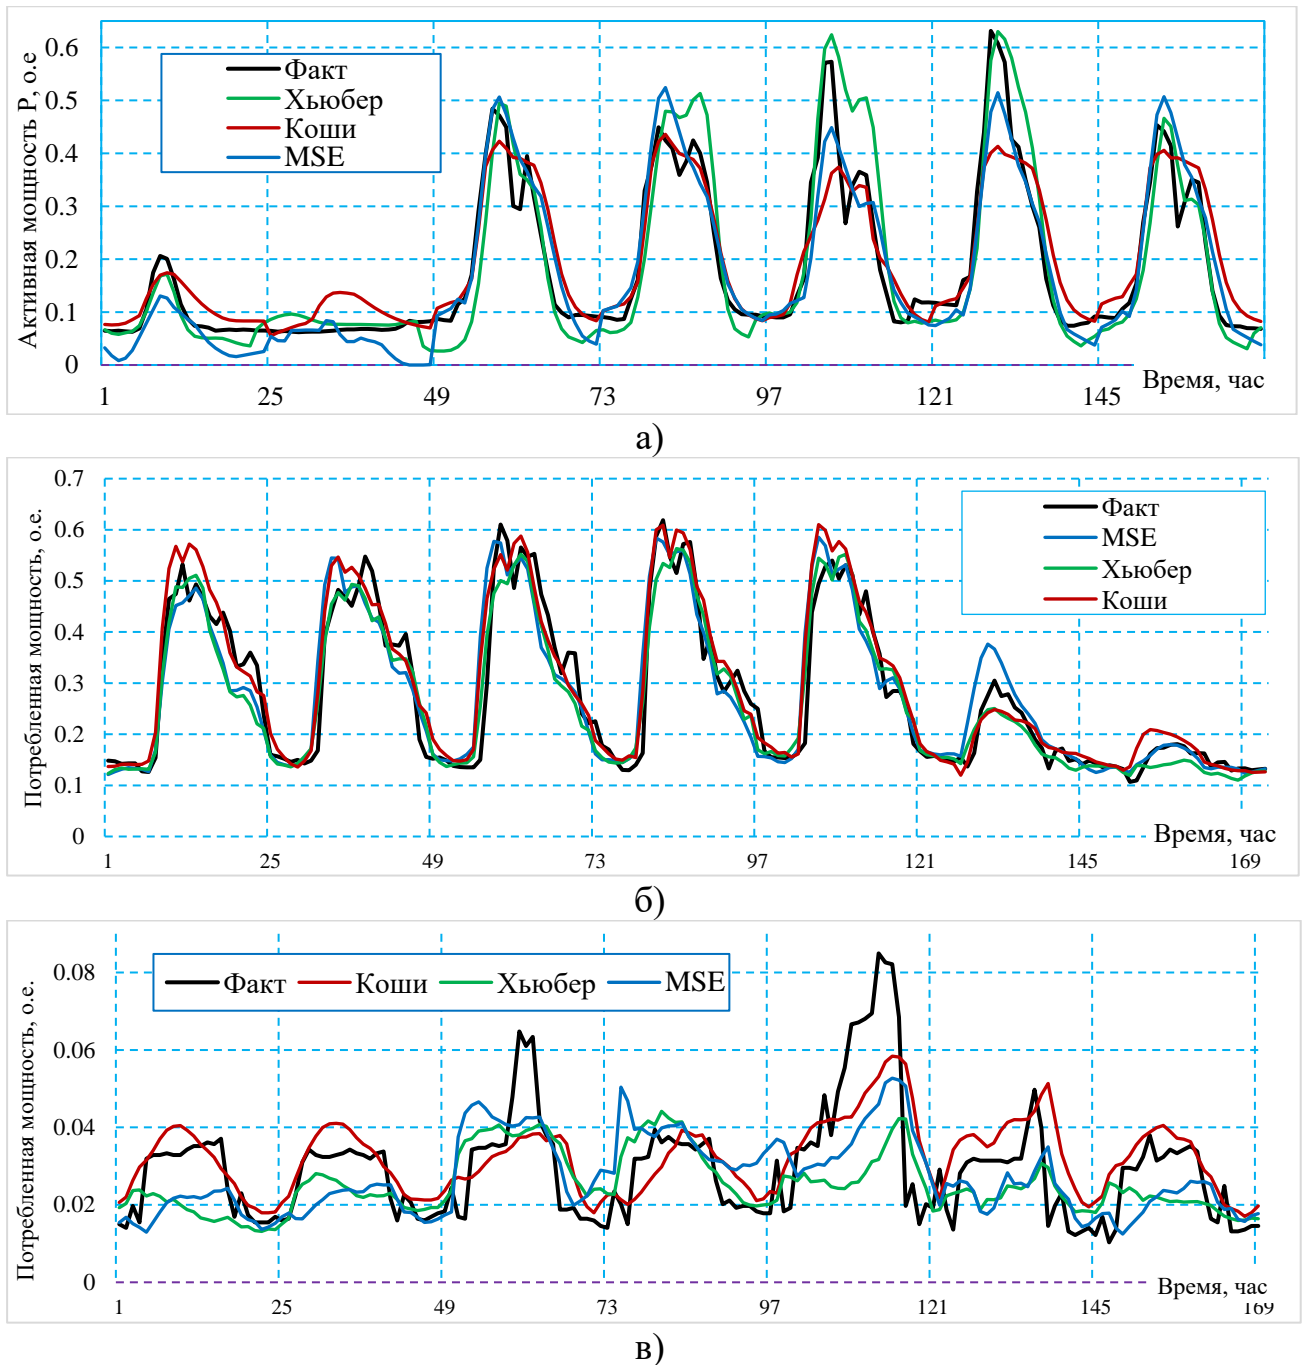


Рисунок 4.6 – Сравнение графиков прогноза и фактического ЭП для потребителя: а) с аддитивно-случайным профилем; б) с аддитивно-сезонным профилем; в) с аддитивным профилем.

Предложенные методы и алгоритмы были протестированы в лабораторных условиях. Рассматривалось прогнозирование на различные горизонты времени (день/неделя/месяц), при том экспериментально получены данные как о влиянии ГА и СО на точность прогнозирования ЭП, так и применение робастных функций потерь вместо квадратичных. Расчетные значения ошибки прогноза сведены в таблицу 4.5.

Таблица 4.5 – Оценка влияния параметров функции потерь и структуры сети на ошибку прогнозирования

Характер потребления электроэнергии			Погрешность прогнозирования, %											
			Циклический		Аддитивно-случайный		Аддитивно-сезонный		Аддитивный					
									ПС-1		ПС-2		ПС-3	
			Без СО и ГА	ГА Без СО	Без ГА со СО	ГА Без СО	Без СО и ГА	Без СО и ГА	Без СО и ГА	ГА + СО	СО Без ГА	ГА + СО	СО без ГА	ГА + СО
Функция потерь	Ср. квадрат	MSE												
			Месяц	Робастная	Хьюбер	5,46	3,56	9,78	0,38	11,7	2,77	2,48	1,57	4,97
Коши	5,77	3,1			8,4	5,02	12,26	6,93	9,8	3,37	15,7	5,09	10,52	5,74
Ср.квadrat	MSE	5,58		1,7	3,98	1,5	6,24	4,39	4,03	2,02	3,55	8,45	6,1	3,64
Неделя	Робастная	Хьюбер	3,03	3,6	3,11	0,52	3,31	0,89	2,9	0,74	1,45	0,92	5,12	1,95
		Коши	7,14	3,12	7,96	4,9	8,93	6,04	8,46	4,26	9,58	4,29	8,01	4,11
	Ср.квadrat	MSE	3,67	0,6	4,69	2,29	4,16	2,13	2,51	1,20	8,64	3,55	3,14	2,29
Сутки	Робастная	Хьюбер	2,08	1,67	2,75	0,17	2,72	0,77	2,58	0,19	3,09	0,79	2,27	0,95
		Коши	4,29	2,88	9,85	4,26	7,49	4,38	4,45	4,19	6,73	4,12	6,94	3,71

По итогам проведенного исследования были получены следующие выводы:

- Робастная функция потерь Хьюбера позволяет добиться повышения точности прогнозирования до 2% даже для циклического потребителя. При этом важно отметить, что применение СО для таких профилей потребления электроэнергии значительно повышает ошибки прогнозирования;

- для аддитивно-случайного профиля максимальная эффективность была достигнута при применении функции MSE без задействования генетического алгоритма, что позволило уменьшить ошибку на 4%;

- при работе с аддитивно-сезонным профилем применение скользящего окна без оптимизации генетическим алгоритмом негативно отразилось на точности, снизив ее на 60–70%. Наилучшая эффективность в данном случае отмечена у функций потерь Хьюбера и Коши, которые сократили ошибку до 9%;

- в случае работы с аддитивными профилями наибольшая эффективность была продемонстрирована робастной функцией потерь Хьюбера, позволив снизить погрешность прогноза в среднем на 6–7%. При этом применение СО, в отличие от циклических профилей повышает точность прогнозирования;

– подбор гиперпараметров с помощью генетического алгоритма в среднем повысил точность прогноза на 8%. Наилучшие результаты были достигнуты при размере пакета данных (BatchSize) в диапазоне 150–250;

– возрастание значений ошибок прогноза связано с ограничениями модифицированных методов и модели обучения. Реализация алгоритма "с нуля" на Python открывает возможности для дальнейших исследований и снятия данных ограничений;

– несмотря на наличие выбросов во временных рядах аддитивного потребителя, прогнозные значения демонстрируют высокую точность благодаря примененным методам обработки данных и модификации обучения (глава 2, 3, 4), что подтверждено экспериментально (таблица 4.5).

Исследовано влияние различных функций потерь в задаче оптимизации весовых значений НС. Оптимизация заключается в снижении отклонения на выходе сети от целевых значений. Рассмотрены существующие решения на примере работ [52, 75].

В таблице 4.6 сведены значения ошибки прогнозирования, рассчитанные по формуле MAPE для различных функций потерь, применяемых при обучении НС. Предложенный комплекс методов, направленный на оптимизацию структурных гиперпараметров нейронной сети и повышение точности прогнозирования энергопотребления для потребителей с аддитивным профилем, предлагается обозначить CMAN + MLP + SW + GAHO + Huber. Где CMAN – методы оптимизации структуры сети; MLP – многослойный перцептрон; SW – скользящее окно для анализа данных; GAHO – гибридный генетический алгоритм для настройки гиперпараметров; Huber – робастная функция потерь для повышения устойчивости модели.

Таблица 4.6 – Сравнение точность функций потерь

	Функции потерь	Ошибка MAPE
1	MSE	8.6 %
2	MAE	5.7 %
3	Quantile Loss	5.1 %
4	Huber	5.7 %
5	CMAN + MLP+SW + GAHO + Huber	2.7 %

Исследование влияния функции потерь на точность прогноза показало, что комбинированный метод $CMAN+MLP+SW+GAHO+Huber$ обеспечивает среднюю ошибку предсказания энергопотребления 2,7% для аддитивных профилей ЭП. Этот результат превосходит альтернативные подходы.

Подтверждена эффективность применения описанных в предыдущих главах методов и алгоритмов по увеличению точности прогнозирования ЭП.

Выводы по главе 4

Экспериментально определено, что влияние аномалий и выбросов на НС-модель снижается при использовании робастной функции потерь вместо классической квадратичной при обучении НС. Выявлено, что наиболее подходящей для работы как с аддитивными профилями потребления ЭЭ, так и с циклическими, является робастная функция Хьюбера. Результатом применения стало снижение ошибки прогнозирования в среднем на 6–7% по сравнению с квадратичной. Скользящее окно как метод прогнозирования также положительно сказывается на точности работы НС-модели.

Оптимизация НС моделей с помощью генетического алгоритма, описанного в главе 3, продемонстрировала точность нейросетей, в среднем на 2,5% выше.

Разработанный ГА проходил тестирование в лабораторных условиях на потребителях с различными профилями, в том числе аддитивными. По результатам эксперимента была подтверждена возможность применения генетического алгоритма как для автоматизации процесса синтеза структуры НС модели, так и повышения точности получаемых прогнозов (таблица 4.12).

На основании анализа результатов экспериментальных исследований, направленных на оптимизацию архитектуры нейросетевой модели в задачах прогнозирования электропотребления с применением нейросетевого подхода, предлагаются следующие практические рекомендации:

- использовать метрику MAE, показывающую меньшее отклонение прогноза по сравнению с MSE и RMSE;

- для потребителей с аддитивным профилем целесообразно использовать робастную модификацию метода обратного распространения ошибки на основе функции потерь Хьюбера;
- отказаться от использования метода скользящего окна для потребителей с циклическим профилем по причине ухудшения результатов прогнозирования;
- использовать ГА оптимизации структуры НС как обеспечивающий как уменьшение ошибки, так и позволяющий автоматизировать процесс подготовки НС-модели.

Подтверждена эффективность совокупности предложенных методов повышения точности прогнозирования. Анализ исследований показал, что совокупность методов $SMAN+MLP+SW+GAHO+Huber$ обеспечивает среднюю ошибку прогнозирования (ЭП) 2,7% для аддитивных данных, демонстрируя наилучший результат. Реализация этих алгоритмов в виде Python-модулей позволит интегрировать их в единую платформу прогнозирования.

Глава 5. РАЗРАБОТКА МЕТОДОЛОГИИ ПОМОЩИ ПРИНЯТИЯ РЕШЕНИЙ В КОНТУРЕ УПРАВЛЕНИЯ SCADA

Современные SCADA-системы, являясь ключевым инструментом управления распределительными энергосетями, сталкиваются со сложностями как при принятии решений, особенно в условиях неопределенности процессов потребления ЭЭ и нестационарности данных и, как следствие, повышающейся сложностью обработки информации и принятия решений в условиях неопределенности. Ограничения, свойственные для традиционных систем ДУ, требуют внедрения систем поддержки принятия решений для получения возможности в реальном времени проводить оперативный анализ больших объемов данных и вырабатывать оптимальные управляющие воздействия в условиях неполноты информации. Ключевая ценность интеграции СППР с SCADA заключается в возможности системного анализа множества факторов, включая текущие параметры сети, прогнозные данные, исторические тенденции и внешние воздействия.

Постановка задачи. Создать алгоритм, способный работать в условиях неопределенности процессов (график электропотребления, зависящий от нужд потребителя, слабо или полностью не поддающийся прогнозу) и неполноты имеющейся информации. СППР в контуре SCADA обеспечивает не только мониторинг и визуализацию данных, но и поддержку диспетчеров при выборе удовлетворительных режимов работы сети. Это позволяет формализовать процесс принятия решений, минимизировать влияние человеческого фактора и повышая надежность управления.

Основная цель создания СППР для SCADA-систем – воспроизвести поведение системы, чтобы проверить работу системы в условиях, приближенных к реальным. Симулятор должен сочетать методы системного анализа, обработки информации и управления сложными техническими системами, обеспечивая при этом повышение эффективности и надежности управления энергосетями.

С учетом специфики процессов и информационной среды, введены следующие требования и ограничения:

- ограничение критериев оптимизации минимизация отклонения прогнозных величин от профильных и заказанных объемов. Учет других факторов, учитываемых диспетчером не производится;

- ограничение системы прогнозирования и ППР принципом «человек в контуре» – СППР является помощником в принятии решений и не заменяет собой оператора;

- требуется разработать удобный интерфейс для оператора, который наглядно показывает результаты работы алгоритма и рекомендации;

- требуется обеспечить возможность дообучения прогностической модели при изменении профиля потребления.

5.1. Упреждающее управление в энергосистемах

Подход к прогнозированию на основе искусственных нейронных сетей учитывает ключевые факторы влияния, включая температурные колебания и изменения объемов производства, что существенно повышает точность прогнозов по сравнению с традиционными методами.

Методика обладает следующими преимуществами: высокая точность прогнозов, адаптивность к изменяющимся условиям и возможность интеграции в системы автоматизированного управления энергопотреблением. Это позволяет снизить погрешности прогнозирования и оптимизировать режимы энергопотребления в реальном времени.

Управление потреблением электроэнергии обеспечивает снижение затрат на эксплуатацию зданий на 10-30% без уменьшения объемов выпускаемой продукции за счет энергосберегающих мероприятий и выравнивания суточных графиков нагрузки. Актуальность темы связана с необходимостью повышения энергоэффективности зданий в рамках мировых тенденций по снижению выбросов CO₂ и других загрязняющих веществ на 20-40%.

Задачей модуля принятия решений является формирование, оценка и выбор приоритетных альтернатив для управления энергосистемой. Исследование

включает разработку системы поддержки принятия решений и многокритериальной модели управления потреблением электроэнергии.

Таким образом, приоритет темы управления электропотреблением связан с необходимостью эффективного и рационального покрытия переменной части – полупиковой и пиковой части графика (рисунок 5.1), которые образуют зону переменной нагрузки) графиков электрической нагрузки энергосистем, а также с повышением эффективности работы систем электроснабжения промышленных предприятий.




Рисунок 5.1 – График электрической нагрузки энергосистемы

Управление объектами подразделяется на:

- программное (на основе априорной информации);
- позиционное (на основе априорной и текущей информации).

Разработка систем упреждающего управления требует тщательного обоснования и использования методов прогнозирования. Прогнозирование является ключевым элементом принятия управленческих решений, поскольку конечная эффективность зависит от событий, возникающих после принятия решения.

Суть упреждающего управления заключается в ориентации объекта и субъекта управления на внешнее окружение с целью выявления возникающих тенденций. На основе анализа этих тенденций проектируются управляющие воздействия для изменения условий функционирования объекта. Выбор стратегии должен опираться на объективную информацию, прогнозные оценки и аналитические выводы.

Системный анализ позволяет выполнить декомпозицию процесса управления электропотреблением, увеличить период упреждения и повысить точность прогноза, что критически важно для эффективного функционирования автоматизированных систем управления.

Прогнозирование электропотребления является важнейшей частью планирования в энергетике. Нейросетевое прогнозирование с использованием искусственных нейронных сетей позволяет обрабатывать большие объемы данных и обеспечивает высокую точность прогнозов, необходимую для эффективного управления энергосистемами.

5.1.1 Методы упреждающего управления

Совокупность методов, используемых для принятия управленческих решений на всех его этапах, подразделяется на три основные группы: формальные, эвристические и методы экспертных оценок. Наличие глубокого математического обоснования делает формальные методы оптимальными для решения хорошо структурированных проблем. Для случаев с высокой степенью неопределенности (слабо- и неструктурированные проблемы) преимущественно применяются эвристические и экспертные подходы.

Функция формирования и принятия решений является системообразующей, поскольку именно она интегрирует все элементы организации в единое целое. Решение – это ключевой продукт и основной инструмент управленческой системы. С данной точки зрения, управленческий процесс предстает в виде непрерывной последовательности актов выбора и принятия решений.

В управлении энергопотреблением применяются различные методы принятия решений, направленные на оптимизацию использования энергоресурсов, снижение затрат и повышение энергоэффективности. Эти методы можно разделить на несколько категорий:

1) Аналитические методы:

– статистические методы – анализ исторических данных потребления энергии, выявление закономерностей и прогнозирование;

– методы многокритериальной оптимизации – выбор наилучшего решения с учетом нескольких факторов (стоимость, надежность, экологичность).

2) Математическое моделирование и оптимизация:

– линейное и нелинейное программирование – минимизация затрат на энергию при заданных ограничениях;

– динамическое программирование – оптимизация энергопотребления в динамических системах (например, управление нагрузкой в реальном времени).

3) Методы искусственного интеллекта и машинного обучения:

– нейронные сети – прогнозирование энергопотребления на основе больших данных;

– генетические алгоритмы – поиск оптимальных режимов работы энергосистем;

– алгоритмы кластеризации – выявление групп потребителей с похожими паттернами потребления;

– обучение с подкреплением – адаптивное управление энергопотреблением в умных сетях.

4) Экспертные системы и системы поддержки принятия решений (DSS):

– базы знаний – использование экспертных оценок для выбора стратегий энергоменеджмента;

– когнитивные карты – моделирование влияния различных факторов на энергопотребление.

Конфигурация системы ППР, при которой проводится мониторинг потребления и закупленной электроэнергии как в целом, так и пофидерно, обеспечивает эффективность и надежность работы энергосетей. При этом потери энергии сводятся к минимуму.

В рамках данного подхода управляющая подсистема, интерпретируя слабые сигналы и выявляя формирующиеся тренды во внешней среде, разрабатывает и применяет корректирующие воздействия на объект управления, тем самым трансформируя его исходные параметры.

В настоящее время процедуры прогнозирования зачастую организационно и технологически обособлены. Интеграция этих процессов способна создать значительный синергетический эффект в управлении электросетевым комплексом. Это становится достижимым благодаря наделению автоматизированной системы учета электроэнергии новым интеллектуальным атрибутом – способностью к прогнозированию («предсказанию») состояния сети [78]. Реализация подобного упреждающего управления открывает возможности для существенной оптимизации как технических, так и экономических результатов функционирования системы. Точность прогнозов напрямую влияет на эффективность планирования и управления [79].

Модели управления. Традиционная модель управления представлена на рисунке 5.2, где траектория функционирования объекта управления (ОУ), оцениваемая по вектору выходных параметров ($Y_1, Y_2, Y_3, \dots, Y_m$), складывается под влиянием входного материально-информационного потока ($X_1, X_2, X_3, \dots, X_m$), непосредственно воздействующего на ОУ внешних возмущений ($P_1, P_2, P_3, \dots, P_m$) и управляющего воздействия, параметры которого ($M_1, M_2, M_3, \dots, M_m$) определяются как функция от входа и выхода объекта.



Рисунок 5.2 – Традиционная (реактивная) модель управления

Применительно к задаче управления потреблением электроэнергии параметры модели управления включают: выходные параметры (Y) – потребляемая мощность $P_{\text{потр}}$; входные параметры (X) – текущее потребление $P(t)$ и $Q(t)$; внешние параметры (P) – метеорологические и социально-экономические факторы; управляющие параметры (M) – ε и прогнозная мощность $P_{\text{прог}}$. Специ-

фика объекта определяется исходными условиями, такими как нормируемые параметры электропотребления (отклонения напряжения, фликер, коэффициент искажения синусоидальности и др.), ожидаемый объем потребления электроэнергии, расчетные параметры окружающей среды, функционально-технические характеристики используемого оборудования. Управление должно быть упреждающим (проактивным) (рисунок 5.3), что предполагает ориентацию как объекта управления (ОУ), так и субъекта управления (СУ) на отслеживание возникающих тенденций в окружении. На основе анализа этих тенденций проектируется управляющее воздействие для изменения исходных условий функционирования объекта.

Проектирование управляющего воздействия включает в себя несколько этапов [80]:

- сбор информации об объекте управления и условиях, в которых он находится. (текущее потребление; ретроспективное потребление; воздействующие метеосоциально-экономические факторы);
- определение значений параметров управляющего воздействия. (каналы и способ передачи сигнала, форма управляющего воздействия);
- формирование управляющего воздействия (конкретного сообщения).



Рисунок 5.3 – Модель упреждающего (проактивного) управления

Схема управления «по слабым сигналам» управления дана на рис. 5.4, где отображены: $X1$ – вектор входного потока; $Y1$ – вектор выходных параметров, описывающий функционирование ОУ; I_x , I_y и I_m – информация о параметрах входного и выходного материально информационного потоков и параметрах состояния объекта управления; $M1$ – параметры управляющего воздействия; $P1$ –

внешние возмущения, непосредственно воздействующие на ОУ и СУ. Модель развивает возможности проактивной модели управления и помогает решать широкий класс управленческих проблем. [81]

К внешним возмущениям ($P_1 - P_n$) относятся:

- отключений питающего электросетевого оборудования 6-110 кВ;
- режима работы потребителей с максимальной мощностью;
- аварийное отключение на сетевом оборудовании;
- смена режима работа промпредприятия;
- отключение горячей или холодной воды.

Это связано с тем, что случайный характер (размытость) данных о параметрах электрической нагрузки не позволяет быть уверенным в том, что в любой момент не произойдет непредвиденная ситуация. Данные факторы создают дополнительную неопределенность при прогнозировании.

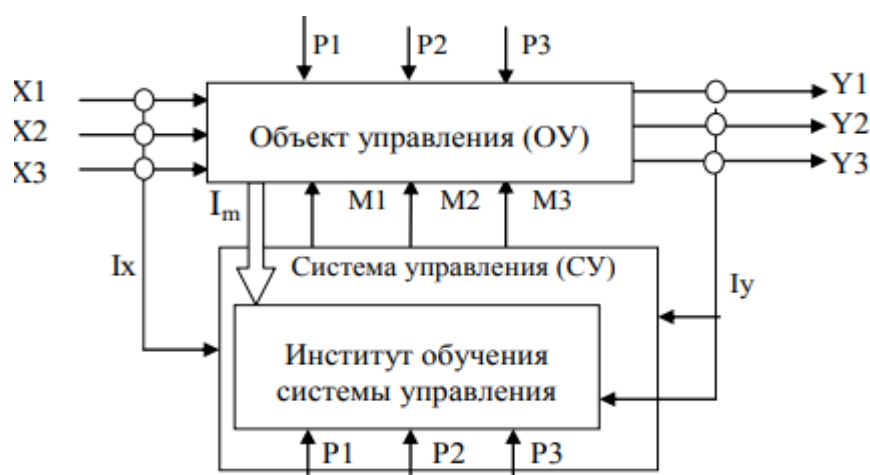


Рисунок 5.4 – Схема рефлексивного управления

Анализ автоматизированных систем управления электрических распределительных сетей показывает, что их развитие происходит в направлении интеграции автоматизированных систем диспетчерского управления (АСДУ) и автоматизированных систем технологического управления (АСТУ) [71]. Обобщенная структурная схема оперативного диспетчерского управления представлена на рисунке 5.5, 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.




Рисунок 5.5 – Замкнутая система оперативного управления

Чаще всего принятие управляющих решений производится «вручную» операторами СДУ. Однако, для выработки альтернатив управляющих решений необходимо применение технологий искусственного интеллекта в виде СППР. Данная система должна иметь ретроспективную, текущую и прогнозную информацию, базу знаний и системный решатель [70], который целесообразно строить на основе нейросетевого моделирования. Поэтому 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 СППР.

Внедрение адаптивной интеллектуальной системы для прогнозирования и децентрализованного управления комплексной энергосистемой обеспечит существенное улучшение ее ключевых показателей:

- **Увеличение бесперебойности:** Будет достигнуто повышение нижнего порога вероятности соответствия параметров электроэнергии (напряжения, тока, частоты) допустимым значениям минимум на 5%. Таким образом, при исходном значении в 90% данный показатель возрастет до 95%.

- **Снижение потерь:** Энергетические потери в системе будут сокращены не менее чем на 20%.

- **Экономический эффект:** Произойдет снижение усредненной стоимости, потребляемой из центральной сети электроэнергии.

5.2. Управление энергосетью с применением нейросетевых моделей и систем поддержки принятия решений

5.2.1 Структура и алгоритм работы нейрокомпьютерной системы

Текущие данные ($V_B, e^0, r, P_{сч}, D, t$) от интеллектуального счетчика (1) и блока регистрации метеофакторов (2) поступают в базу данных (5) нейрокомпьютера (3). Из базы данных они поступают в блок обработки (6), где они нормализуются и далее они могут быть использованы, как для обучения (7), так и для составления прогнозов (8). На входы блоков (9, 10) поступают данные ($V_B, e^0, r, P_{сч}, D, t$) прошедшие нормализацию в блоке (6). Прогнозирование производится с применением метода скользящего окна, при котором прогнозное значение на n часа становится основанием для прогноза для $n + 1$ часа. Блок адаптации (4) выполняет функцию минимизации ошибки. В случае превышения ошибки выше нормы, запускается процесс обучения (7) НС с использованием ГА, где нейронные сети обучаются до тех пор, пока не достигнут необходимого минимума ошибки.

Структура системы мониторинга электропотребления приведена на рисунке 5.6.

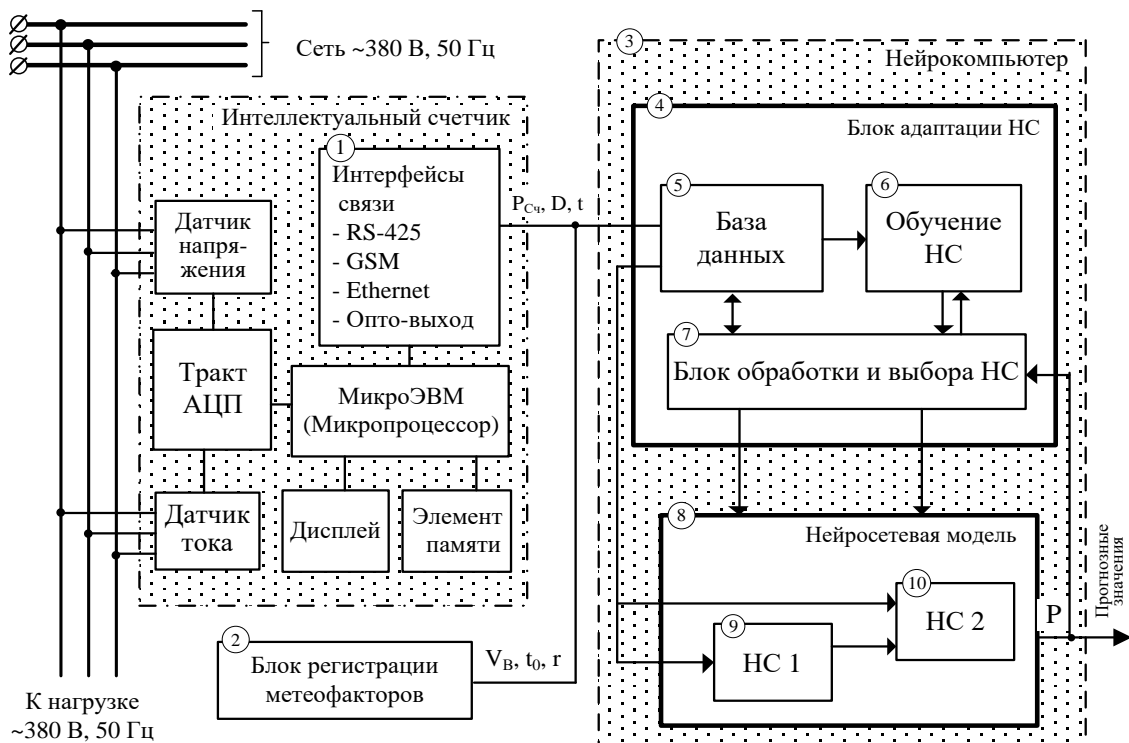


Рисунок 5.6 – Структура системы мониторинга электропотребления

Алгоритм работы устройства. Определение общей структуры НС (кол-во слоев; функции активации; диапазон кол-ва нейронов)

- 1) Обучение набора НС с различным кол-вом нейронов.
- 2) Загрузка набора НС в память внешнего запоминающего устройства НК.
- 3) Загрузка НС (с наименьшей ошибкой) в «Нейросетевую модель».
- 4) Начало работы НК:
 - считывание текущих данных с устройств учета (счетчик + метеопараметры);
 - обработка (нормировка + сглаживание) и запись в БД;
 - подача обработанных значений на вход НС (НС1 – $P(t)$; НС2 – $Q(t)$);
 - получение НС прогнозных значений;
 - вывод прогнозных значений и отправка на оценку.
- 5) Конец работы.

Таким образом, введение СППР в состав нейрокомпьютерной системы прогнозирования повысит эффективность работы ЭС благодаря возможности взаимодействия и управления прогнозированием, что позволит предоставлять необходимую информацию оператору для принятия решений, позволяет, на основании полученных данных. Оператор ДУ РЭС сможет принимать решение о заказе необходимого объема ЭЭ ($\sum P_{\text{прог}}$), получит возможность контролировать возможные всплески и снижения потребления ЭЭ у потребителя (пример приведен на рис. 5.7), тем самым:

- сокращать финансовые затраты на покупку ЭЭ;
- обнаруживать ненормированную работу оборудования;
- дополнительно контролировать адекватность работы НС-модели (вывод расчета погрешности).

5.3. Разработка структуры системы поддержки принятия решений

Ключевые характеристики разрабатываемого симулятора:

- работа на данных, реально снятых с датчиков и счетчиков без предварительной обработки (выполняется в процессе работы программы);

- симуляция погоды – выполняется путем обращения к метеорологическим ресурсам (сайт с прогнозами и архивами погоды);
- симулятор позволяет проигрывать различные сценарии, подавая данные с различными привнесёнными аномалиями для оценки реакции на изменяющиеся условия;
- основным результатом выводимый программой – метрики точности прогноза, рекомендации к действию и отчеты о стабильности.

5.3.1. Функциональные требования к системам поддержки принятия решений в энергосетях

Требования, предъявляемые к прототипу СППР, соответствуют ГОСТ Р 52611–2006 «Средства информационной поддержки жизненного цикла продукции. Безопасность информации» и ГОСТ ИСО/МЭК 15408-1-2012 «Методы и средства обеспечения безопасности.

Критерии оценки безопасности информационных технологий» и являются следующими:

1) Функциональные характеристики. Система поддержки принятия решений должна представлять совокупность методических и программных средств решения задач:

1.1. Автоматическое формирование исходного датасета на основе интеллектуальных технологий, в том числе и получение метеорологических данных с внешних источников.

1.2. Прогнозирование потребления электроэнергии несколькими методами, т.е. должен быть выбор метода прогнозирования.

1.3. Графическое отображение счетчиков, по которым будет выполняться прогноз значения потребления электроэнергии.

1.4. Сохранение результата в файл, в том числе и прогнозной ошибки для проведения сравнительного анализа с другими методами.

1.5. Вход в систему должен быть доступен после регистрации пользователя.

2) Используемые методы прогнозирования. Для прогнозирования потребления электроэнергии должны использоваться методы машинного и глубокого обучения.

3) Требования к методическому обеспечению. Методическое обеспечение должно быть реализовано в пользовательском интерфейсе системы, который должен предполагать; выбор метода прогнозирования; формирование и сохранение исходного датасета в базу данных, а также прогнозных значений потребления электроэнергии в БД.

4) Требования к надежности согласно ГОСТ 27.002–2021, т.е. система должна сохранять во времени в установленных пределах значения всех параметров, необходимых для прогнозирования, в том числе и характеризующих способность системы выполнять требуемые функции в режиме авторизации. В этой связи необходимо:

4.1. Предусмотреть контроль вводимой информации и блокировку некорректных действий пользователя при работе с системой;

4.2. Обеспечить корректное завершение вычислений прогнозных значений при превышении имеющихся вычислительных ресурсов.

5.3.2. Реально-прогнозное управление на основе взаимодействия системы поддержки принятия решений и SCADA-систем

При планово-упреждающем управлении распределительными электрическими сетями требуется прогнозная информация от модели объекта о потреблении электроэнергии с разным горизонтом. Для этого в контур управления дополнительно включаются, подсистема прогнозирования и система поддержки принятия решений – ППР (рисунок 5.7), где: 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; $F_1(t)$, $F_2(t)$, $F_n(t)$ – внешние воздействия, влияющие на характер потребления (погодные условия, смена графика работы, изменения цен и др.).

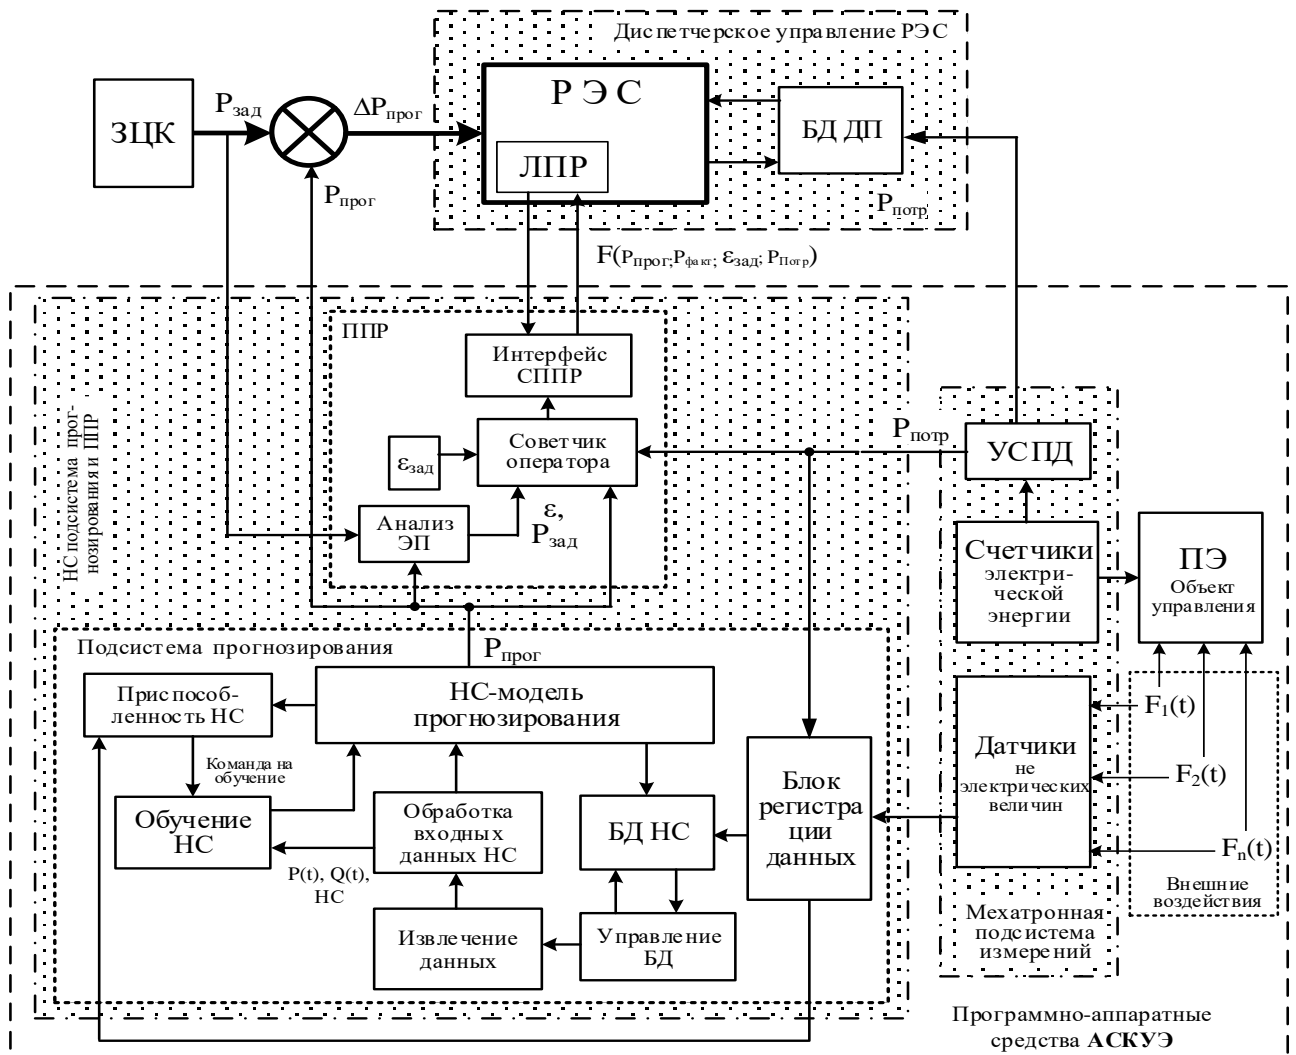


Рисунок 5.7 – Структурная схема реально-прогнозного управления

Система «нейросетевого прогнозирования и логической поддержки» (NDFLS) может использоваться в системах технологического управления региональными сетевыми компаниями, составляющего основу иерархической автоматизированной информационно измерительной системы контроля и учета электроэнергии. Она оптимизирует управляющие воздействия (переключения потребителей, ввод резерва и т.д.) путем выдачи рекомендаций лицу принимающему решения для минимизации отклонения от заказанного объема ЭЭ, поддержания качества ЭЭ. Ключевая особенность реально прогнозного управления – принцип скользящего горизонта, при котором прогнозирование выполняется на необходимый интервал времени, но управляющие решения принимаются на ближайшие сутки. Затем прогноз повторяется с учетом последних данных, поступивших от датчиков, что делает управление адаптивным к реальным возмущениям. В

ходе разработки устройства прогнозирования и ППР зарегистрированы интеллектуальной деятельности в виде патентов на полезные модели [82-84].

Сформулированы требования к методам, реализующим процесс принятия решения.

1) Адаптивность. Ввиду того, что электрические сети являются сложной динамичной системой, обеспечение возможности приспособления к меняющимся внешним условиям, развитию технологий, появлению новых видов оборудования.

2) Устойчивость. Исходные данные для решения задачи прогнозирования нагрузки ЭЭС могут обладать неполнотой, неточностью, зашумленностью и субъективностью. Поэтому принятие решения на основе таких данных должно осуществляться с учетом возможных выбросов.

3) Быстродействие. Решаемая задача по выбору альтернатив с одной стороны, не имеет жестких требований к временным затратам, однако предпочтительным является сокращение затрачиваемых ресурсов и адекватное время работы СППР, особенно при обработке большого объема входных данных.

4) Минимизация участия человека. Для повышения объективности принятия решения управлению электроэнергетическими системами, оно должно осуществляться при минимальном субъективном воздействии человека на промежуточных стадиях процесса принятия решения.

Выявлены следующие основные этапы процесса принятия решения по управлению электропотреблением сложных электроэнергетических систем:

- оценка прогнозных, фактических и профильных данных;
- определение критериев принятия решения. ($\varepsilon_{\text{прог}} = \varepsilon_{\text{прог}}$);
- оценка шаблонов управления ЭП ЭЭС по критериям принятия решения;
- выбор предпочтительной альтернативы управления ЭП ЭЭС;
- оценка результатов и обратная связь.

Предлагаемая система планово-упреждающего управления (рисунок 5.7) включает в себя подсистему прогнозирования и подсистему ППР, которые работают следующим образом:


Подсистема прогнозирования. Показатели текущей потребляемой мощности, фиксируемые прибором учета электроэнергии, направляются в диспетчерский пункт через систему УСПД, а также поступают в базу данных нейросетевой системы и в модуль оценки приспособленности НС. В БД НС накапливаются сведения о потребленной электроэнергии, на основании которых формируются обучающие выборки, кроме того, здесь же сохраняются лучшие нейросетевые конфигурации с различными наборами гиперпараметров. Модуль обучения НС отвечает за подбор гиперпараметров нейросетевой архитектуры и ее обучение с использованием алгоритма обратного распространения ошибки. Сформированная обученная модель направляется в модуль прогнозирования на базе НС-модели. Инициация процесса обучения может осуществляться либо вручную, либо автоматически по сигналу, поступающему от модуля оценки приспособленности НС. Модуль оценки приспособленности НС рассчитывает величину прогнозной ошибки, сопоставляя данные, полученные от модуля прогнозирования, с фактическими показателями потребленной электроэнергии, поступающими от счетчика.

Работа подсистемы ППР. Система помощи принятия решений (ППР) работает следующим образом.


Блок анализа ЭП выполняет сравнение объема заказанной ЭЭ ($P_{зад}$) и прогнозного значения потребленной ЭЭ ($P_{прог}$) на обозреваемый период.

Рассчитанная погрешность (ε_p) направляется в блок советчика оператора. Блок советчика оператора производит расчет отклонения прогнозных величин потребленной мощности ($P_{прог}$) от фактических ($P_{факт}$) на основании текущих данных, снимаемых со счетчика ЭЭ и полученных в результате работы блока НС-модель прогнозирования. Производит обработку и преобразование данных, поступающих на диспетчерский пульт в удобный для оператора вид. С блока советчика оператора снимаются следующие данные: $F_{P_{факт}; P_{прог}; \varepsilon_p}$ графики зависимости $P_{прог}(t)$ и $P_{факт}(t)$; график отклонения прогноза для потребления ЭЭ выше среднего значения за рассматриваемый период; сообщения об увеличении отклонения прогнозирования больше заданного предела и начале переобучения.

На рисунке 5.8, приведен выводимый в интерфейс график сравнения фактической и прогнозной кривой потребления активной мощности P (рисунок 5.8 а) и реактивной мощности Q (рисунок 5.8 б). Горизонт прогнозирования – временной интервал, в пределах которого выполняется прогноз составляет один месяц (720 часов). Профиль потребителя ЭЭ имеет аддитивно-случайный характер по причине ненормированного графика работы.



а)



б)

Рисунок 5.8 – Фактические и прогнозные профили: а – активной мощности $P(t)$, б – реактивной мощности $Q(t)$

На графики добавлена гистограмма отклонения прогнозного значения от фактического, что позволяет быстрее оценить, как изменения в работе потребителя, так и проконтролировать работоспособность НС-модели.

Таким образом, определены взаимосвязи между иерархическими уровнями автоматизированной системой учета и контроля (АСКУЭ) и подсистем прогнозирования (рисунок 5.7). Многоуровневая структура обеспечивает применение прогнозных данных на разные периоды времени для интеллектуальной системы поддержки принятия управленческих решений подсистемами АСУ электросетей в масштабах электросетевой компании.

Показано, что благодаря одновременному использованию результатов фактических замеров и прогнозных значений электропотребления появляется возможность осуществлять интеллектуальное упреждающее управление режимами работы электрических сетей, что дает существенное улучшение их технических и экономических показателей (см. пар 5.5).

5.3.3. Разработка алгоритма работы системы помощи принятия решений

При реализации системы помощи принятия решений (СППР) необходимо определить способ получения логических выводов, на котором будут строиться рекомендации, выводимые оператору РЭС.

Предлагается использовать в качестве инструмента выработки выводов логику ограниченной рациональности (ЛОР), которая предполагает принятие решений в сложных ситуациях, когда нет достаточно вводных для полного понимания проблемы. Выводы делаются на основе заранее сформированных и рассчитанных вариантов действий экспертами, которые могут меняться со временем.

Основной задачей такой логики – оптимизация ресурсов в условиях неопределенности со стороны разрабатываемой системы ППР, а именно учет временных, ресурсных ограничений на процесс принятия решений и отсутствия или сложности получения информации на момент создания о графике работы потребителя, номенклатуре используемого оборудования, планах проведения ремонта оборудования и т.д. а также учитывая возможность получения недостоверной или неполной информации (зашумленные данные или данные с аномалиями, сбой в работе датчиков и телеметрии, ситуативной неточности прогнозов).

Предлагаемая к использованию логика имеет сходства с дедуктивной логикой – построенной на истинности суждений. Она строится на иерархии правил (ЕСЛИ – ТО), позволяя быстро выдавать решение, следуя жесткой зависимости (например, *если* ожидается превышение потребления реактивной мощности, *то* скорректировать работу оборудования). Но в нашем случае к минусам можно отнести – зависимость от точности показаний датчиков и полноте необходимой для построения вывода информации.

По этой причине, рекомендации, выводимые СППР основываются на правиле «большого пальца», т.е. основываются на экспериментальных данных позволяющих получить удовлетворительный, но не наилучший результат.

Логика выводов. Принятие решения СППР о выводе соответствующих рекомендаций производится на основе сопоставления:

где $W_{\text{прог}}$ – прогнозируемое почасовое потребление; $W_{\text{прог}\Sigma}$ – прогнозируемое суммарное потребление; $W_{\text{факт}}$ – фактическое почасовое потребление; $W_{\text{факт}\Sigma}$ – фактическое суммарное потребление; $W_{\text{проф}}$ – профильное почасовое потребление; $W_{\text{проф}\Sigma}$ – профильное суммарное потребление.

На основе (5) получаем соотношение для определения состояния потребления и заказанного объема

На рисунке 5.9 приведен алгоритм работы СППР, иллюстрирующий логику формирования выводимых сообщений. Вначале производится сбор входных данных. Данные включают в себя информацию о:

- потребленной мощности $P(t), Q(t)$;
- метеорологических и социально-экономических факторах;
- текущая дата и время.

Полученная информация обрабатывается в модуле обработки входной информации. В ходе обработки выполняются следующие операции:

1) **Поиск «провалов»** – фрагментов выборки данных, в которых отсутствуют данные о потреблении электроэнергии и дате. Данное действие необходимо для выявления подобных фрагментов с целью дополнения и обработки обучающей

выборки, а также для получения возможности регистрировать в автоматизированном режиме моменты потенциального отказа измерительных устройств или проблем на пути передачи данных от счетчиков до УСП.;

2) **Поиск повторяющихся значений.** Повторяющимися считаются те значения, которые не изменялись на протяжении некоторого количества периодов снятия данных (например, 3-5 часов);

3) **Нормировка.** (см § 2.2);

4) **Сглаживание** методом скользящего среднего. (см § 1.2).

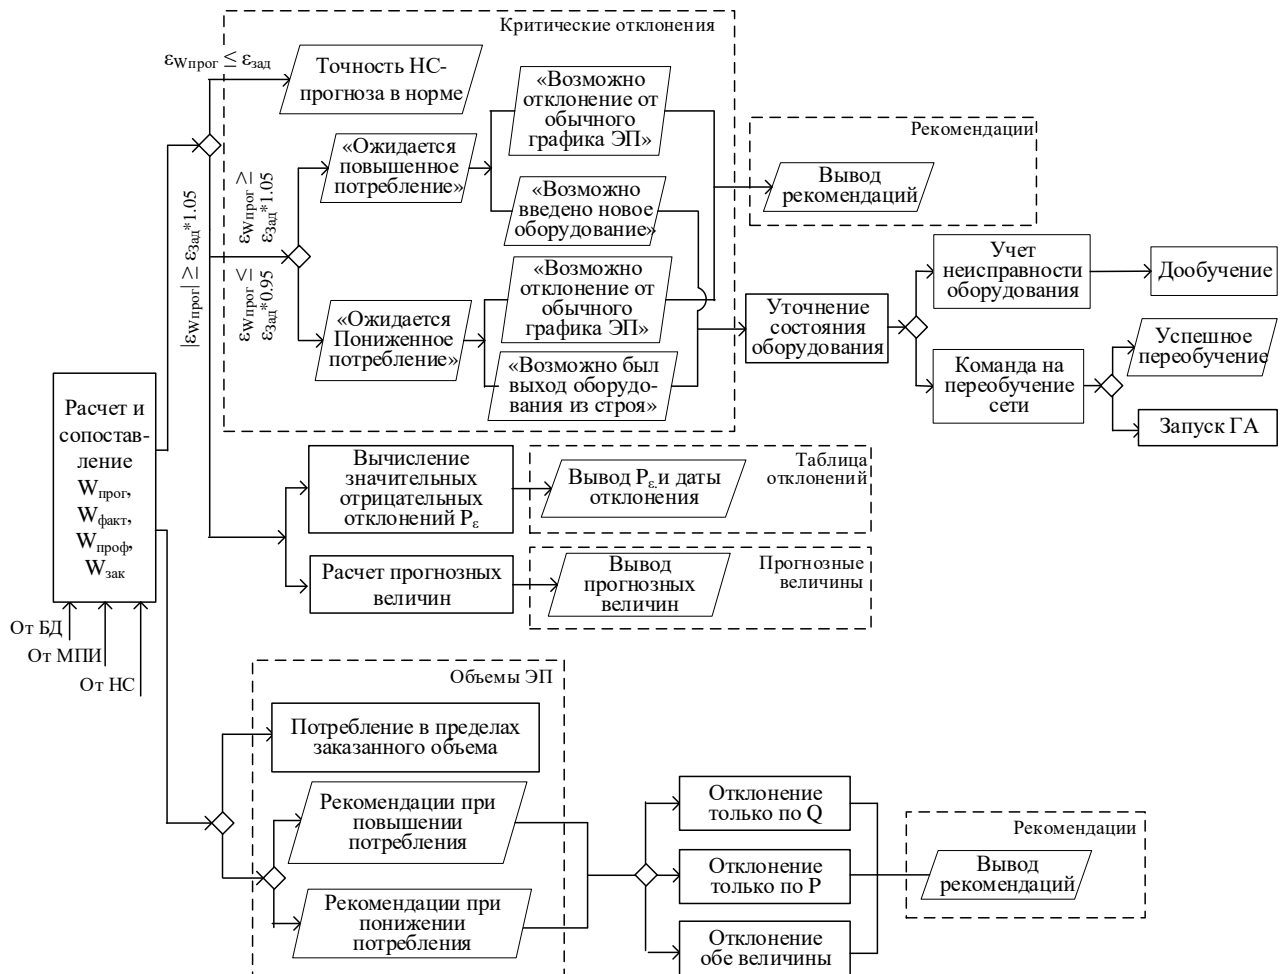


Рисунок 5.9 – Алгоритм работы системы помощи принятия решений

Модуль НС-прогнозирования принимает обработанную информацию и подает ее на входные нейроны НС-модели. Прогнозирование может осуществляться на различные горизонты времени, задаваемые оператором, а также способ прогнозирования ЭП (использование скользящего окна или нет).

Выполняется сбор информации и расчет необходимых величин ($P_{\text{прог}}$ – прогнозные значения от НС; $P_{\text{потр}}$ – фактические значения от счетчика (или БД); $P_{\text{зад}}$ – Объем заказанной ЭЭ; $\varepsilon_{\text{зад}}$ – допустимое отклонение; $\varepsilon_{P_{\text{прог}}}$ – Отклонение прогнозных значений от фактических).

Производится поиск $P_{\text{проф}}$ – значений потребленной мощности на интервал времени, аналогичный прогнозному. Поиск выполняется с учетом месяца, дня недели и статуса дня (рабочий/выходной). При отсутствии наиболее свежих ретроспективных данных в месяц прогноза используются усредненные данные за прошлые года.

Далее приведено описание ветви алгоритма, отвечающего за установление возможного отклонения потребления в большую или меньшую сторону:

Если $\varepsilon_{P_{\text{прог}}}$ меньше $\varepsilon_{\text{зад}}$, то проводится проверка статуса дня, для которого составлялся прогноз. В случае выходного дня выводится сообщение о допустимости отклонения, поскольку в выходные дни ЭП как правило снижено. В противном случае ЛПР информируется о возможном снижении ЭП и отклонении от обычного графика работы, как причина снижения ЭП предполагается выход из строя оборудования потребителя.

Если $\varepsilon_{P_{\text{прог}}}$ превышает $\varepsilon_{\text{зад}}$, то оператору выводится сообщение «Ожидается повышенное потребление» и «Возможности отклонения от обычного графика ЭП», в противном случае, расхождение может быть обусловлено введением в работу нового оборудования, о чем ЛПР уведомляет соответствующее сообщение.

В случае вывода сообщений об отклонении от график потребления, предполагаемом вводе или выводе оборудования из строя, от оператора требуется уточнить состояние оборудования у потребителя и выбрать, исправно оборудование или нет. Если имеет место выход из строя, рекомендовать устранить неисправность оборудования и повторить прогнозирование. В противном случае – выводится сообщение о возможной неисправности НС-модели прогнозирования. И запрос на переобучение модели.

Если после переобучения ошибка остается слишком большой, то оператор получает запрос от программы на запуск ГА подбора параметров НС-модели.

Блок «Анализ ЭП». Выполняет сравнение общего объема электроэнергии которое будет потреблено согласно прогнозу и значений о ЭП за предыдущий период времени, аналогичный прогнозному.

Производится расчет отклонений спрогнозированной мощности от профильного значения $P_{\text{проф}}$, $P_{\varepsilon_{\text{ср}}}$ как в виде отклонения по сумме потребленной мощности, так и в виде отклонения за каждый час с учетом знака P_{ε} . $P_{\varepsilon_{\text{ср}}}$ и P_{ε} выводятся в интерфейс программы управления прогнозированием и СППР

Далее сравниваются значения мощности $P_{\text{проф}}$ и $P_{\text{зад}}$:

1) В случае их равенства – выводится сообщение «Потребление в пределах заказанного объема».

2) Если $P_{\text{проф}}$ больше – выводится сообщение «Потребление снижено. Уточнить будущий объем».

3) Если $P_{\text{зад}}$ больше – выводится сообщение «Потребление повышено. Необходимо до закупки. Уточнить будущий объем».

Модуль «Интерфейс ППР». Осуществляет взаимодействие оператора с программой прогнозирования и ППР (рисунок 5.5). Модуль отвечает за:

1) Прием вводимых данных для прогнозирования и команд от оператора.
 2) Проверку вводимых данных на предмет корректности ввода.
 3) Формирование ответного вывода (подтверждение, ошибка). Например, при вводе некорректной даты (несоблюдение формата) окно ввода окрашивается в красный цвет, блокируется выполнение дальнейших действий, вывод предупреждающего сообщения.

4) Передачу корректных данных исполнительным модулям (прогнозирование, ППР, обработка данных). Перевод данных в необходимый для работы принимающего модуля вид и размерность.

5) Обеспечение обратной связи о состоянии процесса (запись лога выполняемых действий).

б) Отображение некоторых выбранных параметров. Например – выбор рассматриваемого присоединения из выпадающего списка выполняет: выбор соответствующей прогнозной модели, вывод изображения электрической схемы с выделенным присоединением в соответствующий виджет.

Таким образом, разработано реально-прогнозное управление на основе взаимодействия системы ЛПП и SCADA-системы, позволяющее выводить в интерфейс ЛПП рекомендации на основе полученных данных о прогнозировании и отклонениях от запланированного профиля потребления электроэнергии.

5.4. Разработка программного обеспечения системы прогнозирования поддержки принятия решений

5.4.1. Схема взаимодействия модулей

Описание работы ЭС. Экспертная система (ЭС) включает следующие компоненты (рисунок 5.10):

- **База знаний (БЗ).** Содержит информацию и правила, необходимые для решения задач в конкретной области.
- **Модуль логического вывода** анализирует входные данные, применяет правила из базы знаний и генерирует выводы или рекомендации.
- **Модуль взаимодействия с оператором,** позволяет взаимодействовать с системой, вводить данные и получать результаты.

Подсистема объяснений. Является частью модуля подготовки вывода, передающего в интерфейс оператора ход логических выводов, объясняя, как ЭС пришла к такому заключению.

Правилами для экспертных систем являются факты (например, объемы фактического потребления, объем заказанной электроэнергии, результаты прогноза и т.д.), эвристики и логические связи между различными элементами. Иначе говоря – набор инструкций, применяемый к известным фактам при составлении логического вывода.

Ограниченная рациональность в системах управления электропотреблением учитывается, например, через:

– **Использование заранее просчитанных действий и типовых решений.**

Вместо строгого поиска оптимального варианта применяются алгоритмы, которые выбирают лучшее из найденных при имеющихся ограничениях;

– **Учёт неполноты знаний.** В условиях, когда нет полной информации о характеристиках объекта управления, используются алгоритмы, которые работают на основе экспертных правил;

– **Корректировка работы оборудования.** Например, время включения нагрузок сдвигается в зависимости от времени ожидаемых пиков потребления на менее загруженные часы.



Рисунок – 5.10 Взаимосвязь модулей системы СПДР

1) Модуль регистрации данных. Является частью УСПД, обеспечивающей регистрацию, запись и сохранение данных о потребленной мощности, дате и времени снятия показаний, а метеофакторах, снимаемых с метеостанции.

2) 1-й Модуль обработки входной информации. Выполняет восстановление массива поступающих данных путем «заполнения» пропущенных значений потребленной мощности и соответствующей даты для последующей их замены на спрогнозированные значения. Также выполняет поиск повторяющихся значений.

Выполняет поиск аномалий (значений в ряду данных об ЭП, в которых случались всплески или провалы величин по неизвестным или не учитываемым причинам) при помощи кластеризации методом k-среднего (глава 1).

– БД (база данных). Обеспечивает хранение и доступ к информации, включающей в себя ретроспективные пополняющиеся выборки об ЭП, воздействующих факторах для каждого присоединения.

База данных реализуется в виде набора *xlsx*-таблиц. Доступ к ним осуществляется при помощи прямого обращения по адресу расположения. Пример реализации одной из таблиц со входными данными о потребителе приведена в Приложении Б.

3) Модуль извлечения данных. Должен обеспечивать корректное обращение к БД, и перенаправление необходимой информации в нужном формате. Вызов выборки из таблицы, соответствующей нужному потребителю.

4) 2-й Модуль обработки входной информации. Выполняет подготовку данных перед подачей на входные нейроны НС-модели прогнозирования. Производит нормировку и сглаживание ряда данных о потребленной мощности (глава 1).

5) Модуль прогнозирования. Включает в себя как сам алгоритм выполнения прогноза (описан в главе 2), так и генетический алгоритм подбора гиперпараметров НС-модели (описан в главе 3). Запуск ГА выполняется по команде ЛПР. Прогнозирование выполняется на один час вперед, затем, полученное значение становится основой для прогноза на следующий час, подаваясь на вход нейросети.

6) Модуль расчетов. Выполняет расчет необходимых отклонения прогнозных величин от профильных (аналогичных периоду прогноза). Расчет выполняется по формуле $MARE$ для каждого часа и для общего объема потребленной мощности.

7) БЗ (База знаний). Хранит НС-модели для каждого присоединения, выполняет поиск профильного значения $P_{\text{проф}}$.

8) Модуль логических выводов. На основании полученных данных и значений расчетов формирует сообщения о принятии необходимых действий и причин. Логика описана в пункте 5.1.3.

9) Модуль подготовки вывода. Выполняет форматирование данных для вывода в окна интерфейса программы, построение графиков.

Выполняется заполнение таблиц по результатам расчетов отклонения прогноза P и Q. Таблицы содержат следующие столбцы: 'Период', 'Прогноз', 'Отклонение', 'Направление' и встраивание таблиц в интерфейс программы.

5.4.2. Реализация алгоритма системы поддержки принятия решений

В качестве способа реализации выбрана визуализация на приборной панели (интерактивная панель с графиками, диаграммами и ключевыми метриками) как наиболее распространённый.

Приведено краткое описание функций демонстратора системы прогнозирования и ППР.

1) Управление прогностическими моделями. Создание структуры НС для прогнозирования потребленной мощности на основе ГА, сохранение и удаление их из БД, выбор модели из БД.

2) Обучение НС. Выбор модели НС, обучающего набора данных, алгоритма обучения и обучение НС – подбор значений в параметрических слоях.

3) Управление обучающими наборами данных. Создание обучающих наборов данных, их сохранение и удаление из БД, выбор набора данных для обучения НС.

4) Формирование рекомендаций. Демонстрация функций рекомендаций для ЛПР на основе логических выводов.

Результаты обучения при работе демонстратора протоколируются, визуализируются и сохраняются. Пример сохраняемого отчета о обучении НС сети приведен в Приложении А.

Разработанный демонстратор готов к использованию в качестве модуля прогнозирования и ППР при управлении комплексной энергосетью на базе экспериментальной установки. Решены задачи обработки обучающих данных и способа настройки прогнозной НС-модели. Реализовано протоколирование, визуа-

лизация и сохранение метаданных, включая модели НС с различными конфигурациями гиперпараметров. Демонстратор дает возможность получать экспериментальные подтверждения эффективности совместного применения рассмотренных подходов, моделей и методов. При функционировании программной диагностической системы в условиях, близких к реальным, могут быть проверены и экспериментально обоснованы исходные предположения, касающиеся точности прогнозирования ЭП, адекватность работы модуля логических выводов. Разработанной функциональности достаточно для решения поставленных задач.

Демонстратор имеет открытую модульную архитектуру, что позволяет встраивать новые модули для дополнительных функций и использовать отлаженные алгоритмы и настроенные модели в производственных программных комплексах. Таким образом будет достигаться поставленная цель создания научно-технического задела для передачи готовых решений на следующие этапы проекта с минимизацией рисков.

Визуализация выводимой информации. Согласно пункту 1.5 требований по разработке СППР (см. раздел 5.3.2), взаимодействие с программой возможно только при регистрации и последующей авторизации пользователя. Логин и пароль хранится в json-файле. Регистрация нового пользователя возможна только при введении сервисного пароль, что не дает вносить изменения базу данных без ведома администратора.

Факт регистрации нового пользователя и авторизации существующего записывается в отдельный текстовый файл.

Интерфейс главного окна программы-демонстратора прогнозирования и ППР приведен на рисунке 5.11.

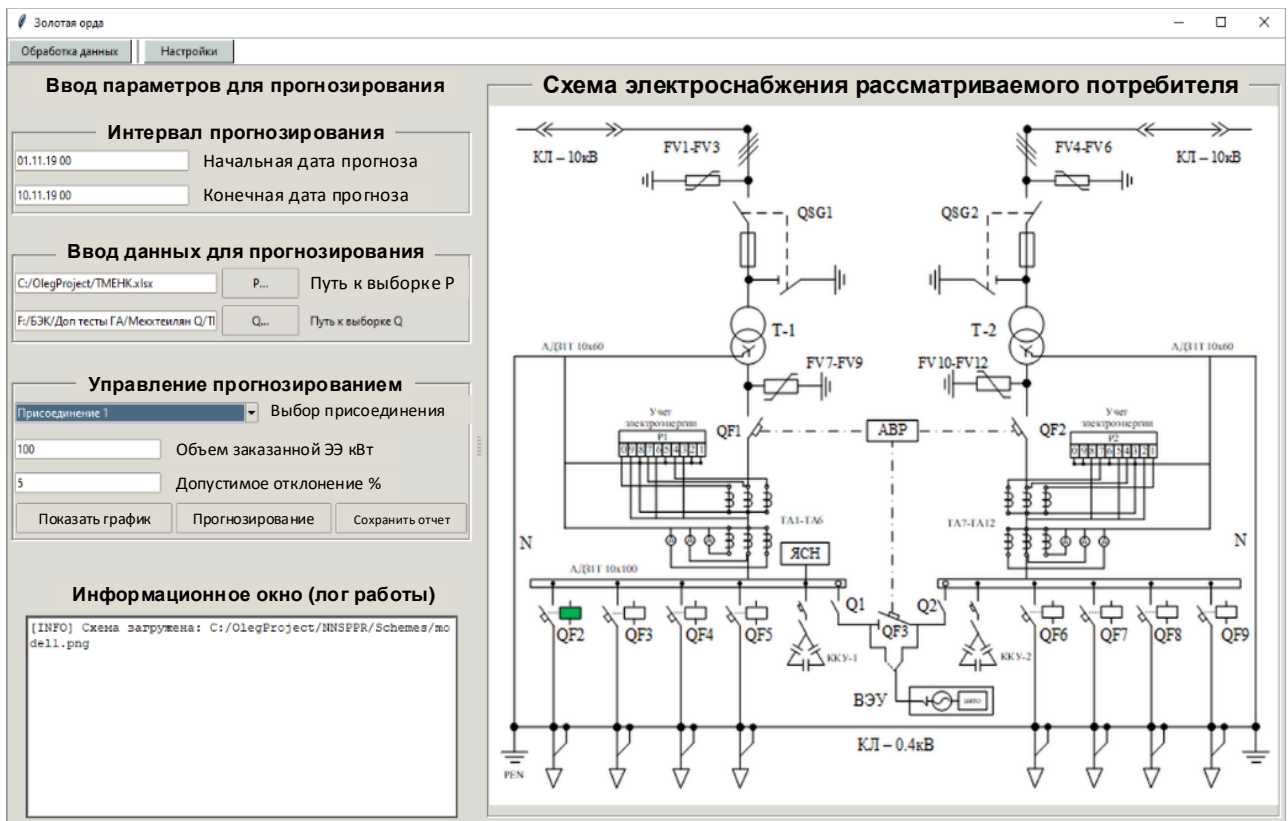


Рисунок 5.11 – Главное окно

Главное окно появляется перед оператором в первую очередь и содержит следующие элементы вывода информации и управления функционалом:

1) Кнопки меню:

– обработка данных (рисунок 5.12) – открывает дополнительное окно.

Позволяет проверить поступившие данные на предмет пропущенных или повторяющихся значений).

– Настройки (открывает окно настроек. В него сведены настройки путей, и некоторые коэффициенты, в частой замене которых нет необходимости).

2) Ввод параметров для прогнозирования:

– указание временного интервала, на который необходим прогноз ЭП;

– указание пути к файлу с данными для прогнозирования;

– выбор интересующего присоединения;

– указание объема ЭЭ, заказанного на рассматриваемый период;

– допустимое отклонение прогноза.

3) Вывод информационных сообщений о ходе выполнения прогноза и ра-

боты программы.

4) Вывод схемы электроснабжения с наглядным указанием рассматриваемого присоединения.

5) Активные кнопки управления:

– Показать график (выводит в отдельном окне график спрогнозированных значений).

– Прогнозирование (запускает прогнозирование и выполнение логических выводов, основываясь как на спрогнозированных значениях, так и на значениях за аналогичный период времени из ретроспективной выборки).

– Сохранить отчет (сохраняет графики и вывод ППП в виде картинки и текста соответственно).

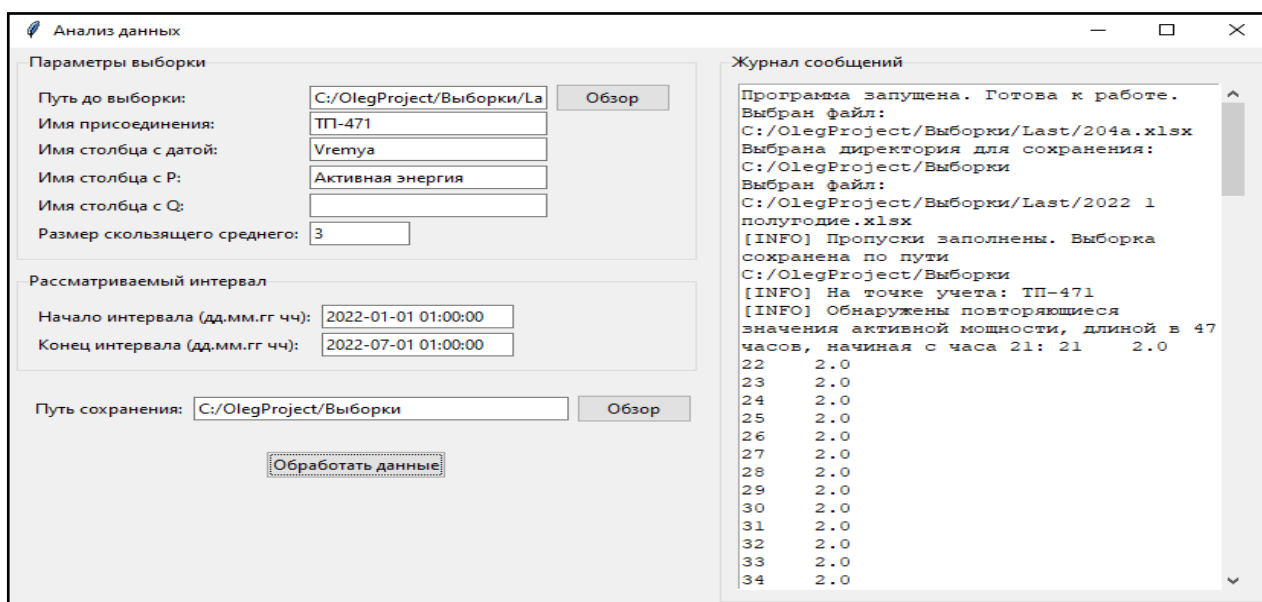


Рисунок 5.12 – Окно обработки данных

Окно содержит следующие элементы управления и вывода:

6) Параметры выборки. Указываются такие параметры как:

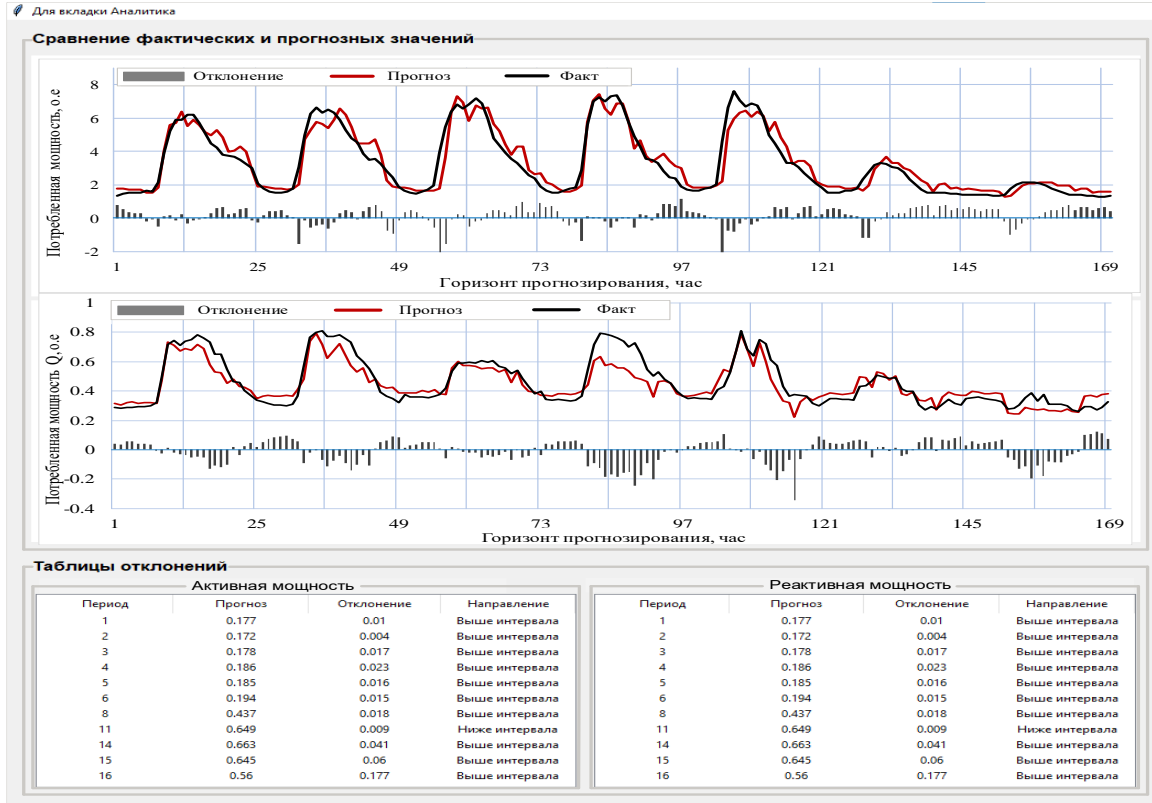
- Путь до рассматриваемой выборки.
- Имя присоединения.
- Имена для столбцов с датой и мощность в выборке.
- Размер скользящего окна для сглаживания выборки (по умолчанию 3).

7) Рассматриваемый интервал.

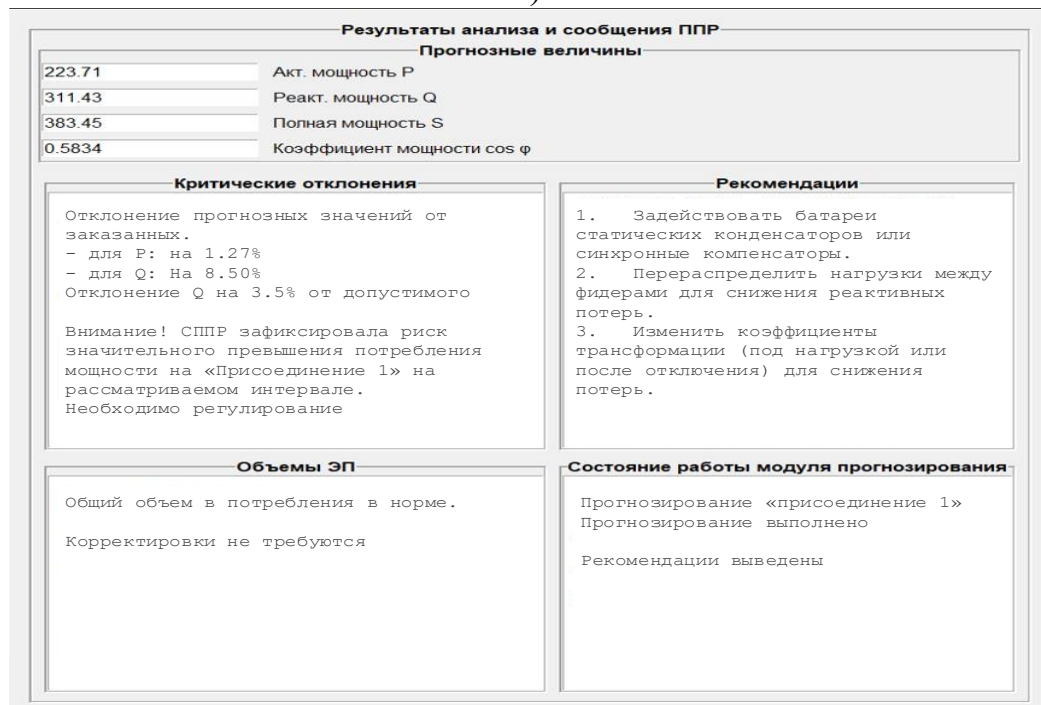
8) Путь для сохранения обработанных данных.

9) Журнал сообщений. Выводит информационные сообщения по ходу выполнения обработки.

На рисунке 5.13 приведено окно выводов СППР (появляется после нажатия кнопки «Прогнозирования» в главном окне).



а)



б)

Рисунок 5.13 – Вывод системы ППР:

а) Сравнение прогнозных и профильных значений б) – сообщения ППР

Окно разделено на 2 части, в левой (рисунок 5.13, а) располагается вывод модуля прогнозирования. Выводятся графики спрогнозированного потребления $P(t)$ и $Q(t)$, значения $P_{\text{проф}}(t)$ и $Q_{\text{проф}}(t)$ (аналогичные периоду прогноза из ретроспективной выборки), доверительный интервал отклонения и точки, в которых наблюдается отклонение в большую или меньшую сторону. Сами значения сводятся в таблицы ниже, указывается час, в который наблюдается значительное отклонение, прогнозное значение, отклонение от профильного значения и в большую или меньшую сторону. Оператор получает информацию об отклонениях технологических переменных, и на основании полученных данных оператор диспетчерского управления РЭС принимает решение о заказе необходимого объема ЭЭ ($\sum P_{\text{прог}}$), получает возможность контролировать возможные всплески и снижения потребления ЭЭ у потребителя, ненормированную работу оборудования, а также дополнительно контролировать адекватность работы НС-модели (вывод расчета погрешности).

В правой части окна (рисунок 5.16, б), в разделе «прогнозные величины» выводятся суммарные значения спрогнозированных величин ($P_{\text{общ}}$, $Q_{\text{общ}}$, $S_{\text{общ}}$) и рассчитанного $\cos\varphi$. Эта часть окна содержит следующие элементы вывода:

- Критические отклонения. Сообщается об отклонении прогнозных значений от аналогичных. В случае превышения допустимого значения ошибки (в данном случае по реактивной мощности) – выводится предупреждение.
- Объемы ЭП. Выводятся суммарные значения прогнозных величин и уже заказанного объема на данный период.
- Рекомендации. В зависимости от типа отклонений и логических выводов выводятся рекомендации к действию для ЛПР.
- Состояния работы модуля прогнозирования. В ходе работы модуля записывается лог действий, позволяющий увидеть, на каком этапе выполнения находится модуль и возможные ошибки в его работе.

5.5 Оценка экономического эффекта от внедрения разработанной модели

Экономический эффект от выполнения данной работы образуется за счет снижения общей ошибки прогнозирования потребления электроэнергии:

- прогнозирование пиковых нагрузок помогает предотвращать перегрузки сетей, уменьшая аварийные отключения;
- выявление аномалий в потреблении снижает неучтенные потери;
- облегчение интеграции в сеть солнечных и ветровых станций за счет прогнозирования генерации ЭЭ;
- снижение затрат на топливо и штрафы за дисбаланс за счет оптимизации ЭП;
- снижение затрат на резервные мощности и перетоки энергии экономит 5–15% операционных расходов.

Расчет затрат на проектирование. Для определения времени, необходимого на проектирование, используется (5.1), которая помогает рассчитать ожидаемую продолжительность работы. Процесс разработки делится на несколько этапов, каждый из которых требует определённое число рабочих часов, как указано в таблице 5.1

$$t_o = \frac{(3t_{\min} + 2t_{\max})}{5}, \quad (5.1)$$

где t_{\min} , t_{\max} – наименьшая и наибольшая длительность работ.

Таблица 5.1 – Трудоемкость разработки

Наименование работы	Длительность работ, часов		
	Минимальная, t_{\min}	Максимальная, t_{\max}	Ожидаемая, t_o
Анализ ТЗ и обзор по теме	50	80	62
Разработка структуры решения	100	150	120
Разработка алгоритмов, моделирование	150	250	190
Разработка и реализация демонстратора	250	350	290
Суммарное количество времени, ч.			662

Оценка эффективности. Для оценки эффективности методики прогнозирования сравним относительные погрешности прогнозных моделей на основе классических методов прогнозирования, методов, применяемых на предприятии

и предложенного метода комбинированного подхода. Сравнение величин ошибок представлено в таблице 5.2.

Таблица 5.2 – Сравнение относительных погрешностей прогнозирования разными методами

№	Метод прогнозирования	Относительная погрешность прогноза %		
		Минимальная	Средняя	Максимальная
1	Классический метод прогнозирования (экспоненциальное сглаживание)	0,047	2,098	4,869
2	Классический метод прогнозирования (регрессионный анализ)	0,403	3,209	9,264
3	Предлагаемый метод прогнозирования	0,17	0,76	2,58

В таблице 5.3 приведен расчет экономического эффекта от использования предложенных методов и алгоритмов прогнозирования и ППР, где номер метода соответствует номеру в таблицы 5.2. Расчет производился по среднему значению отклонения. Фактическое потребление за 2022 год составило 948.77 МВт/ч. Средняя стоимость МВт/ч в 2022 году Ростовской области составляла 4500 руб. При расчете не учитываются издержки за превышение или неполное потребление заказанной ЭЭ и цены на топливо и энергоресурсы, затрачиваемые на производство электроэнергии.

Таблица 5.3 – Расчет экономического эффекта

Расчетные величины	Номер метода		
	1	2	3
Спрогнозировано МВт/ч	968,68	979,22	955,98
Расхождение МВт/ч	19,9	30,44	7,21
Сумма расхождения, руб.	89 573,38	137 007,10	32 447,93

Результаты экономической оценки показали, что предлагаемая программная платформа краткосрочного прогнозирования и ППР значительно точнее классических методов. На данных за 2022 год, средняя ошибка новой модели составила 0,76%, тогда как традиционные методы давали погрешность 2,098% и 3,209%. Это позволило получить экономический эффект в размере 57 125 рублей и 104 560 рублей соответственно. При затратах на разработку в 515 160 рублей и средней годовой экономии 81 000 рублей срок окупаемости проекта составит 6,5 лет.

Выводы по главе 5

1) Определены взаимосвязи между иерархическими уровнями автоматизированной системой учета и контроля (АСКУЭ), разработанных подсистем прогнозирования, ППР и механизма адаптации модели к изменяющимся условиям (рис.5.7). Система предназначена для использования в системах технологического управления региональными сетевыми компаниями. Многоуровневая структура обеспечивает применение прогнозных данных, на разные периоды времени, для интеллектуальной системы поддержки принятия управленческих решений подсистемами АСУ электросетей в масштабах электросетевой компании.

2) При гибридном прогнозировании – ИНС анализирует данные о потребляемой мощности $P_{\text{потр}}$, поступающие с интеллектуальных счётчиков, а СППР сравнивает их с ретроспективными значениями $P_{\text{проф}}$, выявляя возможные аномалии.

Кроме того, одновременное использование в СППР фактических измерений и спрогнозированного ЭП позволяет реализовать реально-прогнозное управление режимами работы электросетей. Оно значительно улучшает их технико-экономические показатели за счёт упреждающего регулирования.

3) Разработана структурная схема реально-прогнозного управления на основе взаимодействия СППР и SCADA-систем управления интеллектуальной энергетической системой (ИЭС) на основе современных интеллектуальных информационно-коммуникационных технологий, средств измерений, передачи, обработки информации.

4) Разработан алгоритм логических выводов на основе логики ограниченной рациональности, что позволяет получать удовлетворительное решение в условиях неполноты имеющейся информации.

5) Разработан программный комплекс «NDFLS» системы прогнозирования и ППР, являющийся алгоритмическим и программным обеспечением анализа данных о электропотреблении и влияющих факторах, прогнозировании объемов потребления ЭЭ на основе искусственного интеллекта (НС-модели) с применением

разработанный алгоритм прогнозирования при помощи скользящего окна для потребителей с аддитивным профилем потребления, подборе оптимальных параметров прогностических моделей для конкретного потребителя при помощи генетического алгоритма. Демонстратор выполняет преобразование и визуализацию прогнозной и профильной информации, расчетов на их основе и вывод в созданный GUI интерфейс программы «Система прогнозирования и ППР».

Новизна предлагаемого прототипа СППР заключается в комбинации предложенных:

- метода обработки данных,
- алгоритма скользящего окна,
- генетического алгоритма синтеза НС,
- ЛОР для формирования рекомендаций и их реализации на единой платформе.

Разработанный программный комплекс обеспечивает:

- Автоматизированную обработку данных с датчиков с использованием метода СМАН, повышающего качество обучения прогностических моделей и точность прогнозирования на 3%.
- Создание выборок для обучения НС на основе, сокращающего время подготовки данных до 3-4 часов.
- Создание нейросетевых моделей с применением генетического алгоритма синтеза структуры НС модели, что позволяет учитывать специфику профиля потребителя.
- Прогнозирование ЭП с точностью от 97% благодаря комбинированному методу СМАН+MLP+SW+GAHO+Huber обеспечивающему среднюю ошибку прогнозирования энергопотребления 2,7%.
- Формирование рекомендаций на основе ЛОР, обеспечивающего вывод удовлетворительных рекомендаций в условиях неполноты данных.

Созданный симулятор прогнозирования и ППР на основе совокупности разработанных методов и алгоритмов обработки данных и повышения точности прогнозирования аддитивных профилей ЭП имеет перспективы дальнейшего

развития в рамках доработки математических моделей, увеличения функциональности, доработки системы формирования логических выводов. Полученные наработки могут применяться для создания программных платформ для прогнозирования и ППР, в которых необходимы автоматическое формирование датасетов и расчета прогнозных значений.

Заключение

1) Экспериментально исследовано влияние различных аномалий во входных данных на качество обучения НС и точность прогнозирования. Выявлены наиболее часто встречающиеся аномалии. При обработки входной информации с целью идентификации, маркирования и устранения проблем в данных предложен метод обработки больших объемов данных. Он отличается совокупностью использования: – метода скользящего среднего для сглаживания небольших выбросов в данных; – кластеризации *k-средних* для борьбы со значительными аномалиями. Предварительная обработка выполняется путем реализации в виде скрипта в Python, как отдельный программный модуль. Это позволяет повысить точность и устойчивость прогностических моделей в условиях высокой вариативности и нестационарности данных.

2) Разработан метод и алгоритм краткосрочного прогнозирования потребления ЭЭ для аддитивных потребителей на основе скользящего окна. Он отличается адаптацией метода пошагового прогнозирования на основе авторегрессии для задач определения объемов потребления электроэнергии с подобранным на основании экспериментальных исследований размером «окна».

Установлено, что для повышения точности прогнозирования оптимален метод скользящего окна (СО), заключающийся в подаче на вход НС последовательности значений потребленной мощности за n предшествующих часов. При таком подходе, прогноз делается на один час за итерацию, затем спрогнозированное значение становится основой для следующего прогноза. Окно может иметь различный объем ретроспективных значений. Экспериментально установлено, что наиболее целесообразно использовать «окно» размером от 3 до 24 часов.

Проведен анализ влияния скользящего окна на точность прогнозирования НС. Установлено, что данный алгоритм прогнозирования позволяет:

- снизить среднюю ошибку прогнозирования на 1,5%;
- повысить точность прогнозов для аддитивных данных.

3) Разработан генетический алгоритм (ГА) для автоматизированного подбора гиперпараметров нейронной сети (НС), которые не определяются в процессе обучения, но существенно влияют на качество прогноза. Метод синтеза структуры НС отличается тем, что генетический алгоритм адаптирован к задачам подбора структурных гиперпараметров и позволяет повысить скорость работы за счет введения первичного тестирования при обучении модели на небольшом количестве эпох.

Проведено обучение и тестирование модели на выборке данных за 2 года (17 520 часов). Сравнение методов подбора гиперпараметров (ручной и с использованием ГА) позволило сделать следующие выводы:

- ГА автоматизирует поиск оптимальных моделей НС;
- точность прогнозов с применением ГА выше в среднем на 2,419%;
- время подбора гиперпараметров сокращается в 6 раз по сравнению с ручным методом.

Исследованы НС, гиперпараметры которых подбирались ГА, а веса корректировались методом обратного распространения ошибки. Анализ результатов позволил установить, что:

- точность прогнозирования зависит от характера данных: для детерминированных закономерностей она выше, чем для аддитивных;
- ручной подбор гиперпараметров требует значительных временных затрат и обработки больших объемов данных;
- применение ГА позволяет находить нестандартные топологии НС, повышая точность прогнозов (на 6-7% процентов).

4) Система управления сложной ЭЭС на основе прогнозирования и поддержки принятия решений реализуется в виде разработанного демонстратора программно-алгоритмического комплекса NDFLS. Программа, реализующая прогнозирование и ППР, отличается объединением предлагаемых методов обра-

ботки информации и прогнозирования. Демонстратор обеспечивает анализ показателей электропотребления и факторов влияния, осуществляет прогнозирование объемов энергопотребления с использованием нейросетевых моделей искусственного интеллекта, а также автоматизирует подбор оптимальных параметров прогностических моделей для индивидуальных потребителей с помощью генетического алгоритма. В функционал NDFLS входит обработка, визуализация и отображение в графическом интерфейсе прогнозных данных, фактических показателей потребления и логических выводов модуля ЛОР.

Практическая значимость результатов работы заключается в том, что:

- разработанные принципы построения прогнозных моделей электропотребления РЭС (ЮЗЭС) могут быть рекомендованы как для других РЭС, так и для прогнозирования электропотребления: в региональных диспетчерских управлениях филиалов «СО ЕЭС» региональных сетевых и энергосбытовых компаниях; в диспетчерских управлениях отдельных предприятий, которые являются участниками оптового или розничного рынков электроэнергии и мощности;
- разработанные алгоритмы и программа прогнозирования электропотребления могут использоваться в составе автоматизированной системы краткосрочного прогнозирования электропотребления;
- предложенный в работе алгоритм корректировки прогноза суточного графика электропотребления, дает возможность повысить точность прогнозирования при различных внешних воздействующих факторах, а также при аддитивном характере электропотребления;
- предложенная СППР выполняет расчет погрешности (ε_p), расчет отклонения прогнозных величин потребленной мощности ($P_{прог}$) от фактических ($P_{номр}$), производит обработку и преобразование данных, поступающих к диспетчеру РЭС в удобный вид;
- результаты могут быть применимы для полноценного электропитания предприятия;

- применение НС позволяет получить точность прогнозирования электропотребления на уровне не менее 96–97%, что дает возможность повысить эффективность энергосбытовых компаний.

Список используемых источников

1. Об электроэнергетике: Федеральный закон РФ от 26.03.2003 № 35-ФЗ // Рос. газета. 2003. 1 апр. С. 1
2. Акметьянов Р. Р., Делегодина Л. А., Копылова Н. П. и др. Задачи прогнозирования энергопотребления в интегрированной АСКУЭ Новосибирского научного центра // Энергосбережение. 2007. № 1. С. 42-47
3. Акметьянов Р. Р., Делегодина Л. А. Копылова Н. П., Луценко Б. Н., Собстель Г. М., Чейдо Г. П. Мультипликативная модель сезонного энергопотребления предприятий // Автометрия. 2008. Т.44, № 3. С. 106-118.
4. Семенова, Н.Г. Методы искусственного интеллекта, применяемые для решения задач энергообеспечения/ Н.Г. Семенова, А.Д. Чернова // Энерго- и ресурсосбережение. Энергообеспечение. Нетрадиционные и возобновляемые источники энергии: Сборник материалов Всероссийской студенческой олимпиады, научно-практической конференции с международным участием. – Екатеринбург: УрФУ, 2013. – С. 234-237
5. Suganya S, Venkatesan T, Ramakrishnan M, Ravi K. Smart utilization of renewable energy sources in a microgrid system integrated with plug-in hybrid electric vehicles. Int J Energy Res. 2018; 42(3)
6. Семенова, Н.Г. Методы искусственного интеллекта, применяемые для решения задач энергообеспечения/ Н.Г. Семенова, А.Д. Чернова // Энерго- и ресурсосбережение. Энергообеспечение. Нетрадиционные и возобновляемые источники энергии: Сборник материалов Всероссийской студенческой олимпиады, научно-практической конференции с международным участием.
7. Хайкин С. Нейронные сети: полный курс, 2-е издание.: Пер. с англ. – М.: Издательский дом «Вильямс», 2006. 1104 с
8. Нейросетевой метод прогнозирования электропотребления и его инструментальная реализация: Н.К. Полуянович, М.Н. Дубяго, Д.В. Бурьков; Южный федеральный университет. – Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2023. – 183 с

9. Шумков Е.А. Система поддержки принятия решений предприятия на основе нейросетевых технологий. Дисс. ... канд. техн. наук. Краснодар: КубГТУ, 2004. 158 с.

10. Чипига А.Ф., Воронкин Р.А. Обучение искусственных нейронных сетей путем совместного использования методов локальной оптимизации и генетических алгоритмов // Известия ТРТУ. Т. 33. №4. С. 172-174

11. Поляхов Н.Д., Приходько И.А., Ван Ефэн. Прогнозирование электропотребления на основе метода опорных векторов с использованием эволюционных алгоритмов оптимизации // Современные проблемы науки и образования. – 2013. – № 2

12. Wang Z., Srinivasan R. S. A review of artificial intelligence-based building energy use prediction: contrasting the capabilities of single and ensemble prediction models // Renewable and Sustainable Energy Reviews. 2017. Vol. 75. P. 796–808. DOI: 10.1016/j.rser.2016.10.079

13. Li S., Wang P., Goel L. A novel wavelet-based ensemble method for short-term load forecasting with hybrid neural networks and feature selection // IEEE Transactions on Power Systems. 2016. Vol. 31, Issue 3. P. 1788–1798. DOI: 10.1109/TPWRS.2015.2438322

14. Моргоева А.Д. и др. Прогнозирование потребления электрической энергии промышленным предприятием с помощью методов машинного обучения // Известия Томского политехнического университета. Инжиниринг георесурсов. 2022. Т. 333. № 7. 115–125

15. Грицай А.С. Почасовое прогнозирование потребления электроэнергии при помощи аппарата нейронных сетей // Динамика систем, механизмов и машин. 2007. №1. С. 194-198.

16. López M., Sans C., Valero S., Senabre C. Empirical comparison of neural network and auto-regressive models in shortterm load forecasting // Energies. 2018. Vol. 11 (8). P. 1–19. DOI: 10.3390/en11082080

17. Zheng H., Yuan J., Chen L. Short-term Load Forecasting Using EMD-LSTM Neural Networks with a Xgboost Algorithm for Feature Importance Evaluation // *Energies*. 2017. Vol. 10 (8). P. 1–20. DOI: 10.3390/en10081168

18. Rahman A., Srikumar V., Smith A. D. Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks // *Applied Energy*. 2018. Vol. 212. P. 372–385. DOI: 10.1016/j.apenergy.2017.12.051

19. С.Л. Подвальный, М.А. Лихотин, А.В. Михайлуков, А.К. Донских. Использование рекуррентных сетей для прогнозирования потребления электроэнергии // *Вестник Воронежского государственного технического университета*. Т. 18. № 3. 2022

20. Вялкова С.А., Надтока И. И., Корнюкова О.А. Применение нейронных сетей для прогнозирования электропотребления мегаполиса. // *Russian Internet Journal of Industrial Engineering*. 2023. Vol. 10, no. 4

21. Хомутов С. О., Серебряков Н. А. Создание нейросетевой математической модели краткосрочного прогнозирования электропотребления электро-технического комплекса участка районных электрических сетей 6–35 кВ // *Транспортные системы и технологии*. 2020. Т. 6, № 1. С. 80–91. DOI: 10.17816/transsyst20206180-91

22. Huo J., Shi T., Chang J. Comparison of random forest and SVM for electrical short-term load forecast with different data sources // *7th IEEE International Conference on Software Engineering and Service Science (ICSESS)*. IEEE, 2016. Pp. 1077–1080. doi: 10.1109/ICSESS.2016.7883252

23. Ensemble deep learning for regression and time series forecasting / X. Qiu, L. Zhang, Y. Ren, P. Suganthan, G. Amaratunga // *Symposium on Computational Intelligence in Ensemble Learning*. IEEE, 2014. Pp. 21–26. doi: 10.1109/CIEL.2014.7015739

24. Short-term residential load forecasting based on LSTM recurrent neural network / W. Kong, Z. Dong, Y. Jia, D. Hill, Y. Xu, Y. Zhang // *IEEE Transactions on Smart Grid*. 2019. Vol. 10. No. 1. Pp. 841–851. doi: 10.1109/TSG.2017.2753802

25. Ryu S., Noh J., Kim H. Deep neural network based demand side short term load forecasting // *Energies*. 2016. Vol. 10. No. 1. Pp. 1–20. doi: 10.3390/en10010003
26. Chen K. Wang Q., He Z., Hu J., He J. Short-Term Load Forecasting with Deep Residual Networks. *IEEE Trans. Smart Grid*. 2019, vol. 10, no. 4, pp. 3943–3952. doi: 10.1109/TSG.2018.2844307
27. Improving accuracy and generalization performance of small-size recurrent neural networks applied to short-term load forecasting / P.V. Matrenin, V.Z. Manusov, A.I. Khalyasmaa, D.V. Antonenkov, S.A. Eroshenko, D. Butusov // *Mathematics*. 2020. Vol. 8. No. 12. Art. no. 2169. doi: 10.3390/math8122169
28. Филатова Е.С., Филатов Д.М., Стоцкая А.Д. Система краткосрочного прогнозирования электропотребления. // *International journal of applied and fundamental research* № 10, 2015
29. Луханина О.В. Простые методы обработки. Достоинства и недостатки / О.В. Луханина, К.И. Мотылев, В.В. Паслен // *Донецкий Национальный Технический Университет* 2024.
30. FasterCapital. Нормализация данных. Роль нормализации данных в оптимизации операций запуска [Электронный ресурс]. URL: <https://fastercapital.com/ru/content/Нормализация-данных.-Роль-нормализации-данных-в-оптимизации-операций-запуска.html> (дата обращения: 17.03.2025)
31. Калинин А.Е. Сравнительный анализ методов выявления аномального уровня электропотребления // *Гроблемы и перспективы развития электроэнергетики и электротехники. III Всероссийская научно-практическая конференция Казань, 2021 с. 203-208*
32. Политов Евгений Александрович, Воронов Иван Викторович, Ефременко Владимир Михайлович Использование нейронной сети для краткосрочного прогнозирования электропотребления промышленного предприятия // *Вестник КузГТУ*. 2006. №6-1.

33. 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(972). – С. 36-41

34. Pereira, João & Silveira, Margarida. (2018). Unsupervised Anomaly Detection in Energy Time Series Data Using Variational Recurrent Autoencoders with Attention. 1275-1282. 10.1109/ICMLA.2018.00207.

35. Shi, Heng & Xu, Minghao & li, Ran. (2017). Deep Learning for Household Load Forecasting – A Novel Pooling Deep RNN. IEEE Transactions on Smart Grid. PP. 1-1. DOI: 10.1109/TSG.2017.2686012

36. Гутовцев А.Л. Современные принципы автоматизации энергоучёта в энергосистемах // Промышленные АСУ и контроллеры. 2003. № 4. С. 4-10

37. 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.

38. Литвинчук С.Ю. Информационные технологии в экономике. Анализ и прогнозирование временных рядов с помощью Excel [Текст]: учебное пособие / С.Ю. Литвинчук; Нижегород. гос. архит.-строит. ун-т. Н.Новгород:– ННГАСУ, 2010. – 78 с

39. Стационарность временных рядов. Как анализировать нестационарные данные. Machine learning guru. [Электронный ресурс]. URL: https://mlgu.ru/1245/?utm_source=yandex&utm_medium=organic. (Дата обращения: 14.07.2025)

40. Без права на провал [Электронный ресурс] / ред. А. Гавриленко // Коммерсантъ. – Электрон. дан. – Москва, 2025. – URL: <https://www.kommersant.ru/doc/7923105> (дата обращения: 10.09.2025)

41. Дед А.В., Сикорский С.П., Смирнов П.С. Результаты измерений показателей качества электроэнергии в системах электроснабжения предприятий и организаций // Омский научный вестник, 2018, № 2(158). С. 60–63

42. Севостьянов А.А. О влиянии провалов и прерываний напряжения на режимы функционирования промышленных систем электроснабжения // «Электроэнергия. Передача и распределение» № 6(81), ноябрь-декабрь 2023

43. Хайндман, Р. Дж. Прогнозирование: принципы и практика / Р. Дж. Хайндман, Дж. Атанасулопулос; пер. с англ. О. О. Герасименко, Н. В. Лукашова, А. В. Стрижов. – 2-е изд. – Электрон. дан. – Москва, 2018.

44. Esmaeilzadeh H., Mohammadi I., Karimi A. Detection of Abnormal Consumption Patterns Using Data Mining Techniques for Electricity Theft Detection Proceedings of the IEEE International Conference on Industrial Technology (ICIT) (2014)

45. Обзор методов предобработки данных, Система непрерывного обучения Predictica [Электронный ресурс] URL: https://predictica.ru/upload/medialibrary/030/0qaslhirbyxwtgma24728ejrk3j7eidt/Preobrabotka-dannykh-v.1021.01_2.pdf Дата обращения (01.03.2025)

46. О. М. Шубат, Д. В. Блинов Исследование рядов динамики в экономике и менеджменте Екатеринбург 2018 Учебный электронный текстовый ресурс URL: https://study.urfu.ru/Aid/Publication/13795/1/Блинов%2C%20Шубат_ЭОР.pdf

47. Ключев Р.В., Моргоева А.Д., Гаврина О.А., Босиков И.И., Моргоев И.Д. Прогнозирование планового потребления электроэнергии для объединенной энергосистемы с помощью машинного обучения // Записки Горного института. 2023. Т. 261. С. 392-402

48 Harish, Battula & Panda, Debasmita & Konda, Krishna. (2023). A Comparative Study of Forecasting Problems on Electrical Load Timeseries Data using Deep Learning Techniques. 10.36227/techrxiv.23532108.

49. Jiang, Ping & Ma, Xuejiao & Liu, Feng. (2015). A New Hybrid Model Based on Data Preprocessing and an Intelligent Optimization Algorithm for Electrical Power System Forecasting. Mathematical Problems in Engineering. 2015. 10.1155/2015/815253.

50. Ahmad, Ahmad & Xiao, Xun & Mo, Huadong & Dong, Daoyi. (2025). TFTformer: A novel transformer based model for short-term load forecasting. International Journal of Electrical Power & Energy Systems. DOI: 10.1016/j.ijepes.2025.110549.
51. Shabad, Prem Kumar & Alrashide, Abdulmueen & Mohammed, Osama. (2021). Anomaly Detection in Smart Grids using Machine Learning. 1-8. DOI: 10.1109/IECON48115.2021.9589851.
52. Сивак М.А. / Робастное обучение нейронных сетей с простой архитектурой для решения задач классификации // Диссертация. Текст. Новосибирск 2022 С. 111
53. Дрейпер, Н. Прикладной регрессионный анализ [Текст] / Н. Дрейпер, Н. Смит. – М. : Статистика, 1973. – 392 с.
54. Рао, С. Р. Линейные статистические методы и их применение [Текст] / С. Р. Рао. – М. : Наука, 1968. – 548 с.
55. Орлов, А. И. Неустойчивость параметрических методов отбраковки резко выделяющихся наблюдений [Текст] / А. И. Орлов // Заводская лаборатория. – 1992. – Т. 58, № 7
56. Rousseeuw, P. J. Robust regression and outlier detection [Текст] / P. J. Rousseeuw, A. M. Leroy. – NY. : John Wiley & Sons, 1987. – 334 p.
57. Haykin, S. Neural Networks and Learning Machines [Текст] / S. Haykin. – 3rd ed. – Pearson Education, 2009. – 906 p.
58. Bishop, C. M. Neural Networks for Pattern Recognition [Текст] / C. M. Bishop. – New York, US: Oxford University Press, 1995. – 502 p
59. Полуянович, Н. К. Построение модели и оценка ее робастности в задаче прогнозирования для потребителей с аддитивными профилями потребления электроэнергии / Н. К. Полуянович, О. В. Качелаев, М. Н. Дубяго // Известия ЮФУ. Технические науки. – 2025. – № 1(243). – С. 104-118. – DOI 10.18522/2311-3103-2025-1-104-118

60. Regression Metrics [Электронный ресурс] / GeeksforGeeks A computer science portal for geeks, URL: <https://www.geeksforgeeks.org/regression-metrics>
Дата обращения (05.11.24)

61. Полуянович, Н. К. Оценка влияния гиперпараметров нейросети на точность прогнозирования энергопотребления / Н. К. Полуянович, О. В. Каче-лаев, Т. Э. Фалькон // Известия ЮФУ. Технические науки. – 2024. – № 4(240). – С. 64-79. – DOI 10.18522/2311-3103-2024-4-64-79

62. Журавлева Наталья Александровна / Выбор оптимизатора для обучения сверточной нейронной сети: задача классификации лесных пожаров // StudNet. 2022. №5.

63. Основные функции активации в нейронных сетях [Электронный ре-сурс] // Статьи по программированию. URL: <https://www.yourtodo.ru/posts/osnovnyie-funksii-aktivatsii-v-nejronnyih-setyah/> (04.07.2024)

64. Kandanand, Karin. (2011). Forecasting Electricity Demand in Thailand with an Artificial Neural Network Approach. *Energies*. 4. 1246-1257. 10.3390/en4081246.]

65. Jun Lin, Jin Ma, Jianguo Zhu, Yu Cui, Short-term load forecasting based on LSTM networks considering attention mechanism / *International Journal of Electrical Power & Energy Systems*, Volume 137,2022,ISSN 0142-0615, <https://doi.org/10.1016/j.ijepes.2021.107818>.

66. Forecasting of Electrical Energy Consumption Using Hybrid Models of GRU, CNN, LSTM, And ML Regressors *Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications* December 24, 2024

67. Курейчик В.М. Генетические алгоритмы: Монография. Таганрог: Изд-во ТРТУ, 1998. 242 с

68. Контрольная работа: Понятие прогноза и методы прогнозирования. Трейдинг [Электронный ресурс] URL: http://siteas.ru/referaty_po_psihologii/kontrolnaya_rabota_ponyatie_prognoza_i.html Дата обращения (01.04.2025).

69. Джимми У. Ки / Искусственные нейронные сети управления технологическими процессами. Часть 2 // «Перспектива», Control Engineering, Россия #4 (64), 2016

70. Алатов Е.В. Подсистема обучения нейронных сетей с использованием генетических алгоритмов: дис. ... маг. техн. и технол. : 09.04.01, Пенза 2017

71. Чипига А.Ф., Воронкин Р.А. Обучение искусственных нейронных сетей путем совместного использования методов локальной оптимизации и генетических алгоритмов // Известия ТРТУ. Т. 33. №4. С. 172-174.

72. Gruau F. Genetic synthesis of Boolean neural networks with a cell rewriting developmental process. // Combination of Genetic Algorithms and Neural Networks, IEEE Computer Society Press, 1992

73. Шумков Евгений Александрович, Чистик Игорь Константинович Использование генетических алгоритмов для обучения нейронных сетей // Научный журнал КубГАУ. 2013. №91.

74. Божич В.И., Лебедев О.Б., Шницер Ю.Л. Разработка генетического алгоритма обучения нейронных сетей // Известия ТРТУ. Тематический выпуск. 2001. Т. 22. №4. С. 170-174

75. Zhou, Yihong & Ding, Zhaohao & Wen, Qingsong & Wang, Yi. (2022). Robust Load Forecasting Towards Adversarial Attacks via Bayesian Learning. Power Systems, IEEE Transactions on. 1-1. 10.1109/TPWRS.2022.3175252

76. Оптимизация структуры системы прогнозирования энергопотребления с атипичным характером энергопотребления / Н. К. Полуянович, О. В. Качелаев, М. Н. Дубяго, С. Б. Мальков // Известия ЮФУ. Технические науки. – 2024. – № 3(239). – С. 207-219. – DOI 10.18522/2311-3103-2024-3-207-219

77. N.K. Poluyanovich, O.V. Kachelaev, M.N. Dubyago, A.A. Shurykin. Hybrid algorithm for optimization of hyperparameters of neural network model of electricity consumption forecasting. 2024 6th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA), Lipetsk, Russian Federation, 2024, pp. 276-280

78. Староверов Б.А. Повышение эффективности системы автоматизированного коммерческого учета электроэнергии за счет введения функций прогнозирования / Б.А. Староверов, Б.А. Гнатюк // Вестник ИГЭУ. 2013. №6. С. 26-29

79. Полуянович Н. К. Нейросетевой метод прогнозирования электропотребления и его инструментальная реализация: Монография / Н. К. Полуянович, М. Н. Дубяго, Д. В. Бурьков. – Ростов-на-Дону – Таганрог: Южный федеральный университет, 2023. – 183 с. – ISBN 978-5-9275-4632-9. – DOI 10.18522/801317381

80. Сафаралиев М.Х. / Разработка моделей прогнозирования электропотребления и генерации ГЭС на среднесрочную перспективу в изолированных энергосистемах // Дисс. К.т.н. Уральский энергетический институт, Екатеринбург – 2022

81. Управление предприятием (организацией): учебное пособие / В.В. Лихолетов. – Челябинск: Издательский центр ЮУрГУ, 2021. – 279 с.

82. О. В. Качелаев, Н. К. Полуянович, М. Н. Дубяго. Устройство мониторинга и прогнозирования электропотребления в электроэнергетических системах на основе нейронных структур. / Патент на полезную модель №222420. Дата регистрации: 12.10.2023. Дата публикации: 25.12.2023. Заявка № 2023126166

83. О. В. Качелаев, Н. К. Полуянович, М. Н. Дубяго. Интеллектуальное устройство прогнозирования режимов электропотребления энергосети для повышения надежности и энергоэффективности / Патент на полезную модель №226794. Заявка № 2024107423, Дата публикации: 24 июня 2024 г

84. О. В. Качелаев, Н. К. Полуянович, М. Н. Дубяго. Интеллектуальное устройство упреждающего прогнозирования режимов энергопотребления и помощи принятия решений / Патент на полезную модель № № 235546, Заявка № 2025106843, Дата регистрации 08.07.2025

ПРИЛОЖЕНИЕ А

Сохраняемый отчет по результатам обучения

Дата создания: 2025-05-29 15:22:47

=====

1. Архитектура модели:

Всего параметров: 19,841

Обучаемые параметры: 19,841

Необучаемые параметры: 0

Слои:

Слой 1: Dense (dense_150)

Нейроны: 150

Активация: relu

Параметры: 1,200

Слой 2: Dense (dense_80_1)

Нейроны: 80

Активация: relu

Параметры: 12,080

Слой 3: Dense (dense_80_2)

Нейроны: 80

Активация: relu

Параметры: 6,480

Слой 4: Dense (output)

Нейроны: 1

Активация: linear

Параметры: 81

2. Параметры обучения:

Оптимизатор: RMSprop

Learning rate: 0.0010000000474974513

Функция потерь: mse

Метрики: loss, compile_metrics

Максимальное количество эпох: 400

Ранняя остановка: patience=50 (мониторинг loss)

Размер батча: 32

3. Метрики обучения:

Фактическое количество эпох: 10

loss:

Начальное: 0.0079

Конечное: 0.0026

Изменение: -0.0053

mae:

Начальное: 0.0660

Конечное: 0.0383

Изменение: -0.0277

4. Графики обучения:

График функции потерь сохранен: C:/OlegProject/training_plots\NN1_loss.png

График метрики MAE сохранен: C:/OlegProject/training_plots\NN1_mae.png

ПРИЛОЖЕНИЕ Б

Пример датасета

День	Меяц	Год	Час	Темп	Осадки	Ветер	Статус	P	Q
1	10	21	1	13	0	10	1	18.9	21.06
1	10	21	2	13	0	10	1	19.08	20.79
1	10	21	3	13	0	10	1	19.08	21.54
1	10	21	4	13	0	10	1	20.49	21.78
1	10	21	5	13	0	10	1	20.76	21.66
1	10	21	6	13	0	10	1	19.83	22.77
1	10	21	7	13	0	10	1	13.77	21.87
1	10	21	8	13	0	10	1	71.85	49.59
1	10	21	9	13	0	10	1	358.44	329.1
1	10	21	10	13	0	10	1	346.41	336.84
1	10	21	11	13	0	10	1	356.97	350.85
1	10	21	12	13	0	10	1	319.02	340.8
1	10	21	13	13	0	10	1	239.28	269.76
1	10	21	14	13	0	10	1	197.67	237.33
1	10	21	15	13	0	10	1	230.1	266.43
1	10	21	16	13	0	10	1	189.72	201.81
1	10	21	17	13	0	10	1	67.8	75.72
1	10	21	18	13	0	10	1	11.4	16.2
1	10	21	19	13	0	10	1	15.51	14.55
1	10	21	20	13	0	10	1	18.45	14.16
1	10	21	21	13	0	10	1	18.33	14.07
1	10	21	22	13	0	10	1	18.63	14.1
1	10	21	23	13	0	10	1	19.71	14.37
1	10	21	24	13	0	10	1	19.89	16.71
2	10	21	1	14	0	9	0	21.45	18.45
2	10	21	2	14	0	9	0	19.77	19.89
2	10	21	3	14	0	9	0	21.03	20.46
2	10	21	4	14	0	9	0	20.64	21.66
2	10	21	5	14	0	9	0	20.52	21.09
2	10	21	6	14	0	9	0	20.25	20.52
2	10	21	7	14	0	9	0	12.24	22.44
2	10	21	8	14	0	9	0	10.32	19.5
2	10	21	9	14	0	9	0	9.48	16.74
2	10	21	10	14	0	9	0	9.45	15
2	10	21	11	14	0	9	0	9.84	15.63
2	10	21	12	14	0	9	0	9.9	15.33
2	10	21	13	14	0	9	0	9.21	16.5
2	10	21	14	14	0	9	0	9.39	17.31
2	10	21	15	14	0	9	0	9.42	17.76
2	10	21	16	14	0	9	0	9.6	17.55
2	10	21	17	14	0	9	0	9.18	18
2	10	21	18	14	0	9	0	9.48	17.37
2	10	21	19	14	0	9	0	15.78	14.67

ПРИЛОЖЕНИЕ В

Листинг кода программы

Подпрограмма

Формирование интерфейса программы

НАЧАЛО ПРОГРАММЫ

ИМПОРТИРОВАТЬ необходимые библиотеки:

```
configparser, tkinter, os, PIL, matplotlib, tensorflow.keras, ttkthemes
```

СОЗДАТЬ главное окно root:

```
заголовок: "Золотая орда"  
размер: 1400x700  
минимальный размер: 1000x800  
разрешить изменение размера
```

НАСТРОИТЬ стиль темы 'clam'

ОПРЕДЕЛИТЬ ГЛОБАЛЬНЫЕ ПЕРЕМЕННЫЕ:

```
otstup = 3 (отступ)  
scheme_label = None (для метки схемы)
```

ОПРЕДЕЛИТЬ ФУНКЦИИ:

ФУНКЦИЯ menu_data_proc():

```
СМЕНИТЬ рабочую директорию  
ИМПОРТИРОВАТЬ Data_proc_wind  
ПОЛУЧИТЬ значение допуска ошибки  
ВЫЗВАТЬ обработку данных с параметром tolerance
```

ФУНКЦИЯ menu_settings():

```
ПРОВЕРИТЬ существование файла настроек  
ДОБАВИТЬ путь к модулям Python  
ПОПЫТАТЬСЯ импортировать SettingsWindow  
СОЗДАТЬ дочернее окно настроек
```

ФУНКЦИЯ browse_file(entry_widget):

```
ОТКРЫТЬ диалог выбора файла  
ЕСЛИ файл выбран:  
ОЧИСТИТЬ поле ввода  
ВСТАВИТЬ путь к файлу
```

ФУНКЦИЯ resize_window_to_image(img_width, img_height):

```
РАССЧИТАТЬ новые размеры окна с учетом отступов  
УСТАНОВИТЬ новые размеры окна
```

ФУНКЦИЯ show_plot():

```
СМЕНИТЬ рабочую директорию  
ИМПОРТИРОВАТЬ New_window  
ПОЛУЧИТЬ все параметры из полей ввода  
ПРОЧИТАТЬ настройки из JSON файла  
ВЫЗВАТЬ функцию построения графика sprg() с параметрами
```

ФУНКЦИЯ save_report():

```
ОБНОВИТЬ модель  
ИМПОРТИРОВАТЬ Sutki_prog  
ВЫПОЛНИТЬ прогноз на 24 часа  
РАССЧИТАТЬ результат
```

ФУНКЦИЯ log_message(msg):

```
ДОБАВИТЬ информационное сообщение в лог
```

```

ПРОКРУТИТЬ лог к концу

ФУНКЦИЯ log_error(msg):
    ДОБАВИТЬ сообщение об ошибке в лог
    ПРОКРУТИТЬ лог к концу

ФУНКЦИЯ update_scheme(event):
    ПОЛУЧИТЬ выбранную модель
    ОБНОВИТЬ изображение схемы

ФУНКЦИЯ update_model():
    ПОЛУЧИТЬ выбранное присоединение
    ЗАГРУЗИТЬ соответствующую модель Keras
    ВЕРНУТЬ модель

ФУНКЦИЯ display_image(image_path):
    ПОПЫТАТЬСЯ:
        ОТКРЫТЬ изображение
        РАССЧИТАТЬ размеры для масштабирования
        ИЗМЕНИТЬ размер изображения
        ОБНОВИТЬ или СОЗДАТЬ метку с изображением
        ЗАЛОГИРОВАТЬ успех
    ИСКЛЮЧЕНИЕ:
        ЗАЛОГИРОВАТЬ ошибку

СОЗДАТЬ ИНТЕРФЕЙС:

1. Создать верхнее меню с кнопками:
    - "Обработка данных" → вызывает menu_data_proc()
    - "Настройки" → вызывает menu_settings()

2. Создать главный контейнер с разделением:
    - Левая панель (фиксированная ширина) для управления
    - Правая панель (растягивается) для отображения схемы

3. На левой панели создать секции:
    - Интервал прогнозирования (дата начала/окончания)
    - Ввод данных (пути к файлам P и Q)
    - Управление прогнозированием:
        * Выбор присоединения (выпадающий список)
        * Объем заказанной электроэнергии
        * Допустимое отклонение
        * Выбор типа прогноза (с/без авторегрессии)
        * Кнопки управления:
            - Прогноз на интервал
            - *** (заглушка)
            - Прогноз на 24 часа
    - Информационное окно (лог)

4. На правой панели создать область для отображения схемы электроснабжения

5. Установить обработчики событий:
    - При выборе присоединения обновлять схему
    - При нажатии кнопок вызывать соответствующие функции

ЗАПУСТИТЬ главный цикл обработки событий root.mainloop()

КОНЕЦ ПРОГРАММЫ

```

Подпрограмма

Авторизация, создание нового пользователя, логгирование входа

// Константы

```

КОНСТАНТА SERVICE_PASSWORD = "admin_register_13"
КОНСТАНТА USERS_FILE = "users.json"
КОНСТАНТА LOG_FILE = "auth_log.txt"

// Функция логирования авторизаций
ФУНКЦИЯ log_auth(username)
    timestamp = текущее_время_в_формате("дд-мм-гггг чч:мм:сс")
    ЗАПИСАТЬ В ФАЙЛ LOG_FILE: timestamp + " - Успешная авторизация пользовате
ля: " + username
КОНЕЦ ФУНКЦИИ

// Функция загрузки пользователей
ФУНКЦИЯ load_users()
    ЕСЛИ файл USERS_FILE существует ТО
        ПРОЧИТАТЬ файл USERS_FILE как JSON
        ВЕРНУТЬ данные пользователей
    ИНАЧЕ
        ВЕРНУТЬ пустой словарь
КОНЕЦ ФУНКЦИИ

// Функция сохранения пользователей
ФУНКЦИЯ save_users(users)
    ЗАПИСАТЬ users в файл USERS_FILE в формате JSON
КОНЕЦ ФУНКЦИИ

// Функция главного окна
ФУНКЦИЯ main_window_func(username)
    ПОКАЗАТЬ сообщение: "Добро пожаловать, " + username
    ВЫЗВАТЬ log_auth(username)
    ВЫЗВАТЬ основное_окно_приложения() из MainFile
КОНЕЦ ФУНКЦИИ

// Функция попытки входа
ФУНКЦИЯ try_login()
    username = значение_поля_логина
    password = значение_поля_пароля
    users = load_users()

    ЕСЛИ username пусто ИЛИ password пусто ТО
        ПОКАЗАТЬ ошибку: "Введите логин и пароль!"
        ВЕРНУТЬСЯ
    КОНЕЦ ЕСЛИ

    ЕСЛИ username НЕ в users ТО
        ПОКАЗАТЬ ошибку: "Пользователь не найден!"
        ВЕРНУТЬСЯ
    КОНЕЦ ЕСЛИ

    ЕСЛИ users[username] != password ТО
        ПОКАЗАТЬ ошибку: "Неверный пароль!"
        ВЕРНУТЬСЯ
    КОНЕЦ ЕСЛИ

    ВЫЗВАТЬ main_window_func(username)
КОНЕЦ ФУНКЦИИ

// Функция открытия окна регистрации
ФУНКЦИЯ open_registration_window()
    СОЗДАТЬ новое окно reg_window
    ДОБАВИТЬ поля ввода: сервисный пароль, новый логин, новый пароль
    ДОБАВИТЬ кнопку "Зарегистрироваться"

// Функция регистрации
ФУНКЦИЯ try_register()

```

```

service_pass = значение_поля_сервисного_пароля
new_login = значение_поля_нового_логина
new_pass = значение_поля_нового_пароля
users = load_users()

ЕСЛИ service_pass != SERVICE_PASSWORD ТО
    ПОКАЗАТЬ ошибку: "Неверный сервисный пароль!"
    ВЕРНУТЬСЯ
КОНЕЦ ЕСЛИ

ЕСЛИ new_login пусто ИЛИ new_pass пусто ТО
    ПОКАЗАТЬ ошибку: "Логин и пароль не могут быть пустыми!"
    ВЕРНУТЬСЯ
КОНЕЦ ЕСЛИ

ЕСЛИ new_login в users ТО
    ПОКАЗАТЬ ошибку: "Пользователь уже существует!"
    ВЕРНУТЬСЯ
КОНЕЦ ЕСЛИ

ДОБАВИТЬ new_login: new_pass в users
save_users(users)
ПОКАЗАТЬ сообщение: "Регистрация успешна!"
ЗАЛОГИРОВАТЬ регистрацию пользователя
ЗАКРЫТЬ окно регистрации
    КОНЕЦ ФУНКЦИИ
КОНЕЦ ФУНКЦИИ

// Функция центрирования окна
ФУНКЦИЯ center_window(window, width, height)
    ВЫЧИСЛИТЬ центр экрана
    УСТАНОВИТЬ позицию окна по центру
КОНЕЦ ФУНКЦИИ

// Основная программа
СОЗДАТЬ главное окно root
УСТАНОВИТЬ заголовок: "Авторизация"
УСТАНОВИТЬ размер: 300x200
ЦЕНТРИРОВАТЬ окно

// Создать элементы интерфейса
ДОБАВИТЬ метку "Логин:"
ДОБАВИТЬ поле ввода для логина
ДОБАВИТЬ метку "Пароль:"
ДОБАВИТЬ поле ввода для пароля (скрытое)
ДОБАВИТЬ кнопку "Войти" → вызывает try_login
ДОБАВИТЬ кнопку "Регистрация" → вызывает open_registration_window

// Инициализация файлов
ЕСЛИ файл USERS_FILE не существует ТО
    СОЗДАТЬ файл с пользователем по умолчанию: {"admin": "admin"}
КОНЕЦ ЕСЛИ

ЕСЛИ файл LOG_FILE не существует ТО
    СОЗДАТЬ файл с заголовком журнала
КОНЕЦ ЕСЛИ

ЗАПУСТИТЬ главный цикл обработки событий

```

Подпрограмма

Модуль обработки данных, вызываемый из основного окна программы

```

ФУНКЦИЯ DP(tolerance):
    ИМПОРТИРОВАТЬ необходимые библиотеки: tkinter, os, filedialog

// Вспомогательные функции
ФУНКЦИЯ select_save_dir():
    ВЫБРАТЬ директорию через диалоговое окно
    ЕСЛИ директория выбрана:
        ОБНОВИТЬ поле ввода пути сохранения
        ЗАЛОГИРОВАТЬ сообщение о выборе директории

ФУНКЦИЯ select_file():
    ВЫБРАТЬ файл через диалоговое окно
    ЕСЛИ файл выбран:
        ОБНОВИТЬ поле ввода пути к файлу
        ЗАЛОГИРОВАТЬ сообщение о выборе файла

ФУНКЦИЯ log_message(message):
    ДОБАВИТЬ сообщение в журнал сообщений
    ПРОКРУТИТЬ журнал к последнему сообщению

ФУНКЦИЯ NNlog_message(tab, msg):
    ДОБАВИТЬ информационное сообщение в журнал

// Основная функция обработки
ФУНКЦИЯ D():
    ПОЛУЧИТЬ значения из полей ввода:
        Con_name, xlsx_file, Time_name, P_name
        start_date, end_date, Slide_aver, save_path

    ЕСЛИ обязательные поля не заполнены:
        СООБЩИТЬ об ошибке
        ВЕРНУТЬСЯ

    ФУНКЦИЯ run_external():
        ПОПЫТАТЬСЯ:
            ИЗМЕНИТЬ рабочую директорию
            ИМПОРТИРОВАТЬ DataProcessing из SALO

        ФУНКЦИЯ logging_callback(message):
            ВЫЗВАТЬ NNlog_message("DataProcessing", message)

        ВЫЗВАТЬ DataProcessing с параметрами:
            Con_name, xlsx_file, Time_name, P_name
            start_date, end_date, Slide_aver, save_path
            log_func=logging_callback

        СООБЩИТЬ об успешном завершении
    ИСКЛЮЧЕНИЕ:
        СООБЩИТЬ об ошибке

    ВЫЗВАТЬ run_external()

// Создание графического интерфейса
СОЗДАТЬ главное окно root
НАСТРОИТЬ размер и заголовков окна

СОЗДАТЬ стиль оформления

СОЗДАТЬ разделитель main_paned (горизонтальный)

// Левая панель - параметры
СОЗДАТЬ left_panel

```

```

ДОБАВИТЬ left_panel в main_paned

// Фрейм параметров выборки
СОЗДАТЬ sample_frame
ДОБАВИТЬ элементы:
    - Поле пути к файлу с кнопкой "Обзор"
    - Поле имени присоединения
    - Поля имен столбцов (дата, P, Q)
    - Поле размера скользящего среднего

// Фрейм интервала
СОЗДАТЬ interval_frame
ДОБАВИТЬ поля:
    - Начальная дата
    - Конечная дата

// Фрейм сохранения
СОЗДАТЬ save_frame
ДОБАВИТЬ поле пути сохранения с кнопкой "Обзор"

// Кнопка обработки
СОЗДАТЬ кнопку "Обработать данные" → вызывает D()

// Правая панель - журнал
СОЗДАТЬ right_panel
ДОБАВИТЬ right_panel в main_paned

СОЗДАТЬ message_frame с прокручиваемым текстовым полем

ДОБАВИТЬ начальное сообщение в журнал

ЗАПУСТИТЬ главный цикл обработки событий

КОНЕЦ ФУНКЦИИ DP

```

Подпрограмма

Формирование окна вывода результатов прогноза, визуализации и результатов логических выводов

```

ФУНКЦИЯ sppr(Pzad, tolerance, start_date, end_date, P_file, Q_file, ordered,
connections, Sliding_window_Gap, sliding_window):
    ИМПОРТИРОВАТЬ необходимые библиотеки: numpy, pandas, tensorflow, tkinter,
matplotlib, openpyxl, os, datetime

    // Загрузка моделей нейронных сетей
    ЕСЛИ connections == 'Присоединение 1':
        ЗАГРУЗИТЬ модель для P: 'C:/OlegProject/PNN.keras'
        ЗАГРУЗИТЬ модель для Q: 'C:/OlegProject/QNN.keras'
    ИНАЧЕ ЕСЛИ connections == 'Присоединение 2':
        // Загрузка других моделей
    ИНАЧЕ:
        // Обработка других случаев

    // Создание главного окна
    СОЗДАТЬ главное окно root
    НАСТРОИТЬ размеры и ограничения окна
    УСТАНОВИТЬ стиль оформления

    // Вспомогательные функции
    ФУНКЦИЯ hours_between_dates(date1, date2):

```

```

ПРЕОБРАЗОВАТЬ строки в объекты datetime
ВЫЧИСЛИТЬ разницу в часах
ВЕРНУТЬ количество часов

ФУНКЦИЯ slide_pred(new_data_W, test, X):
    ВЫПОЛНИТЬ прогнозирование с использованием скользящего окна
    ВЕРНУТЬ прогнозные значения

// Основные вычисления
ВЫЧИСЛИТЬ количество часов между start_date и end_date
ЗАГРУЗИТЬ данные из файлов P_file и Q_file
ПОДГОТОВИТЬ тестовые данные и метки

// Прогнозирование
ВЫПОЛНИТЬ прогноз для P: model.predict(P_test_data)
ВЫПОЛНИТЬ прогноз для Q: modelq.predict(Q_test_data)

// Расчет суммарных показателей
ВЫЧИСЛИТЬ суммарные значения P и Q
ВЫЧИСЛИТЬ полную мощность  $S = \sqrt{P^2 + Q^2}$ 
ВЫЧИСЛИТЬ коэффициент мощности  $\cos_{fi} = P/S$ 

// Расчет ошибок
ВЫЧИСЛИТЬ ошибки прогноза для P и Q (абсолютные и относительные)
ВЫЧИСЛИТЬ суммарные ошибки

// Анализ отклонений
ОПРЕДЕЛИТЬ допустимый интервал  $\pm 7\%$ 
НАЙТИ точки прогноза вне допустимого интервала
ВЫЧИСЛИТЬ величину отклонений
СОЗДАТЬ таблицы результатов для P и Q

// Создание интерфейса
СОЗДАТЬ разделенный интерфейс (левая и правая панели)

// Левая панель - графики и таблицы
СОЗДАТЬ фрейм для графиков сравнения
СОЗДАТЬ фрейм для таблиц отклонений (P и Q)

// Правая панель - результаты и сообщения
СОЗДАТЬ фрейм для прогнозных величин:
    - Активная мощность P
    - Реактивная мощность Q
    - Полная мощность S
    - Коэффициент мощности  $\cos \phi$ 

СОЗДАТЬ сетку информационных окон:
    1. Критические отклонения
    2. Рекомендации
    3. Объемы электропотребления
    4. Состояние работы нейросети

// Генерация графиков
ФУНКЦИЯ create_graphs():
    СОЗДАТЬ графики для P и Q с:
        - Фактическими значениями
        - Прогнозными значениями
        - Допустимыми интервалами
        - Выделением точек вне интервала
    ДОБАВИТЬ возможность масштабирования в отдельных окнах

// Логика анализа и рекомендаций
ФУНКЦИЯ logic():
    ПРОАНАЛИЗИРОВАТЬ отклонения

```

```

СФОРМИРОВАТЬ рекомендации на основе:
- Превышения допустимых отклонений
- Сравнения с заказанными значениями
- Анализа режима работы

// Сохранение результатов
ФУНКЦИЯ save_report():
    СОХРАНИТЬ отчет в текстовый файл с:
        - Прогнозными величинами
        - Отклонениями
        - Рекомендациями
        - Состоянием системы

ФУНКЦИЯ save_trees_to_excel():
    ЭКСПОРТИРОВАТЬ таблицы отклонений в Excel

// Запуск процессов
ВЫЗВАТЬ logic() для формирования рекомендаций
ВЫЗВАТЬ create_graphs() для построения графиков
ВЫЗВАТЬ save_report() и save_trees_to_excel() для сохранения результатов

ЗАПУСТИТЬ главный цикл обработки событий

КОНЕЦ ФУНКЦИИ sprpr

```

Подпрограмма

Запрос почасового прогноза погоды для прогнозирования потребления электроэнергии на 24 часа от текущей даты

```

ФУНКЦИЯ pred_24hours(model):
    ИМПОРТИРОВАТЬ необходимые библиотеки: requests, re, BeautifulSoup, dateti
me, pandas, workalendar

    // Настройка параметров HTTP-запроса
    url = 'https://meteofor.md/ru/weather-taganrog-5106/hourly/'
    УСТАНОВИТЬ headers для веб-запроса
    УСТАНОВИТЬ cookies для веб-запроса

    // Выполнение HTTP-запроса
    response = ЗАПРОС_GET(url, headers, cookies)
    ЕСЛИ статус ответа != 200:
        ВЫВЕСТИ ошибку
        ЗАВЕРШИТЬ выполнение

    // Парсинг данных о ветре
    speed_value = НАЙТИ_ВСЕ_СОВПАДЕНИЯ('<speed-value value="([\d.]+"', respo
nse.text)
    wind = ПРЕОБРАЗОВАТЬ_В_ЧИСЛА(speed_value)[-24:]

    // Парсинг данных о температуре
    temperature_value = НАЙТИ_ВСЕ_СОВПАДЕНИЯ('<temperature-value value="([\d.
-]+)"', response.text)
    temperature = ПРЕОБРАЗОВАТЬ_В_ЧИСЛА(temperature_value)[-24:]

    // Парсинг данных об осадках
    soup = BeautifulSoup(response.text, 'html.parser')
    items = НАЙТИ_ВСЕ('div', class_='item-unit', 'item-unit unit-blue'])
    rain = [ТЕКСТ_ЭЛЕМЕНТА(item) for item in items]
    rain = ПРЕОБРАЗОВАТЬ_В_БИНАРНЫЙ(rain)[-24:] // 1 - есть осадки, 0 - нет

    // Парсинг времени
    time_spans = НАЙТИ_ВСЕ('span')
    hours = []

```

```

ДЛЯ КАЖДОГО span В time_spans:
    ЕСЛИ ':' В span.text:
        hour = ИЗВЛЕЧЬ_ЧАС(span.text)
        hours.ДОБАВИТЬ(hour)

// Генерация дат на следующие 24 часа
current_datetime = ТЕКУЩЕЕ_ВРЕМЯ()
future_dates = [current_datetime + timedelta(hours=i) for i in range(1, 2
5)]

// Извлечение компонентов даты
all_days = [date.day for date in future_dates]
all_months = [date.month for date in future_dates]
all_years = [date.year for date in future_dates]

// Определение рабочих/выходных дней
cal = Russia()
status = []
ДЛЯ КАЖДОГО date В future_dates:
    ЕСЛИ cal.is_working_day(date):
        status.ДОБАВИТЬ(1) // Рабочий день
    ИНАЧЕ:
        status.ДОБАВИТЬ(0) // Выходной

// Загрузка исторических данных
data = ПРОЧИТАТЬ_ЭКСЕЛ('C:/OlegProject/TK.xlsx')
dt = data[['Day', 'Mounth', 'Year']].values
pow = data[['P']].values

// Поиск совпадающих значений мощности
prog_date = '01.12.2023'
day, month, year = РАЗБИТЬ_ДАТУ(prog_date)
target_date = datetime(year, month, day)

date_range = [target_date - timedelta(days=i) for i in range(24)]
matched_pow = []

ДЛЯ КАЖДОГО date В date_range:
    day_check, month_check, year_check = date.day, date.month, date.year
    match_found = ЛОЖЬ

    ДЛЯ КАЖДОГО (i, row) В dt:
        ЕСЛИ row[0] == day_check И row[1] == month_check И row[2] == year
_check:
            match_found = ИСТИНА
            matched_pow.ДОБАВИТЬ(pow[i][0])
            ПРЕРВАТЬ_ЦИКЛ

    ЕСЛИ НЕ match_found:
        ВЫВЕСТИ предупреждение о отсутствии данных

// Создание итогового DataFrame
tdf = СОЗДАТЬ_DataFrame({
    'Day': all_days,
    'Mounth': all_months,
    'Year': all_years,
    'Hour': hours,
    'Status': status,
    'Temp': temperature,
    'Rain': rain,
    'Wind': wind,
    'P': matched_pow
})

```

ВЕРНУТЬ tdf

КОНЕЦ ФУНКЦИИ

Подпрограмма

Запуск генетического алгоритма для подбора гиперпараметров прогнозной модели

ФУНКЦИЯ GANN(LF, BS, Epoch, nGen, nInd, TFP, TrFP, SO, SOSize, Mch, Msh):

ИМПОРТИРОВАТЬ необходимые библиотеки: tensorflow, keras, numpy, pandas, time, random, shutil, math, os

```
// Инициализация параметров
Learn_func = LF
Batch_Size = BS
EHs = Epoch
MEHs = nGen
Generation_Size = nInd
MaxSize = 10
Sliding_Window = SO
Sliding_Window_Gap = int(SOSize)
mutationPercent = Mch
mutationRange = Msh
TestFile = TFP
DataFile = TrFP

// Структуры для хранения информации о сетях
Networks_Structure = [] # Архитектуры сетей
Networks_Functions = [] # Функции активации
Networks_Optimizers = [] # Оптимизаторы
Networks_FF = [] # Функции приспособленности

// Загрузка и подготовка тестовых данных
Data_String = ['Day', 'Mounth', 'Year', 'Hour', "Temp", "Status", "Wind",
"Rain"]
ДОБАВИТЬ к Data_String элементы "P1" до "P" + str(Sliding_Window_Gap)

ЗАГРУЗИТЬ тестовые данные из TestFile
ПОДГОТОВИТЬ new_data, new_data_W, test_labels

// Загрузка обучающих данных
ЗАГРУЗИТЬ обучающие данные из DataFile
ПОДГОТОВИТЬ train_data, train_data_W, train_labels

// Определение доступных функций и оптимизаторов
activation_function = ('relu', 'sigmoid', 'softmax', ...)
optimizers = ('sgd', 'rmsprop', 'adam', ...)

// Вспомогательные функции
ФУНКЦИЯ ChooseOpt(number): ВЫБРАТЬ оптимизатор по номеру
ФУНКЦИЯ ChooseActFunc(number): ВЫБРАТЬ функцию активации по номеру
ФУНКЦИЯ Clear_Session(): ОЧИСТИТЬ сессию Keras
ФУНКЦИЯ Create_Model(num): СОЗДАТЬ модель по заданной архитектуре
ФУНКЦИЯ Error_Calculate(num, NNP, TestL): ВЫЧИСЛИТЬ ошибку прогноза
ФУНКЦИЯ Save_Best_Model(): СОХРАНИТЬ лучшую модель и очистить папку
// Основной цикл генераций
start_time = time.time()
ДЛЯ Steps в диапазоне [0, MEHs):

    ЕСЛИ существует сохраненная лучшая модель:
        ЗАГРУЗИТЬ лучшую модель
        ИЗВЛЕЧЬ архитектуру, функции активации, оптимизатор
        ДОБАВИТЬ в соответствующие списки
```

```

// Создание новой популяции на основе лучшей модели
ДЛЯ i в диапазоне [1, 0.7*Generation_Size]:
    СОЗДАТЬ мутировавшую архитектуру
    СОЗДАТЬ мутировавшие функции активации
    СОЗДАТЬ мутировавший оптимизатор
// Добавление случайных особей
ДЛЯ i в диапазоне [0.7*Generation_Size, Generation_Size]:
    СОЗДАТЬ случайную архитектуру
    СОЗДАТЬ случайные функции активации
    СОЗДАТЬ случайный оптимизатор
// Оценка моделей
ДЛЯ MN в диапазоне [1, Generation_Size]:
    СОЗДАТЬ модель Create_Model(MN)
    СКОМПИЛИРОВАТЬ модель с выбранным оптимизатором

    ЕСЛИ Sliding_Window == 1:
        ОБУЧИТЬ модель на trd_W
    ИНАЧЕ:
        ОБУЧИТЬ модель на trd
    ЕСЛИ loss < 0.05:
        ВЫПОЛНИТЬ прогноз:
            ЕСЛИ Sliding_Window == 1: ИСПОЛЬЗОВАТЬ скользящее окн
            ИНАЧЕ: ПРОСТОЙ прогноз

        ВЫЧИСЛИТЬ ошибку Error_Calculate
        СОХРАНИТЬ модель
    ИНАЧЕ:
        УСТАНОВИТЬ высокую ошибку

    СОХРАНИТЬ лучшую модель
    ОЧИСТИТЬ списки

ИНАЧЕ: // Первое поколение
    СОЗДАТЬ случайные модели
    ОЦЕНИТЬ каждую модель
    СОХРАНИТЬ лучшую модель
    ОЧИСТИТЬ списки

// Завершение работы
end_time = time.time()
ВЫВЕСТИ общее время выполнения
КОНЕЦ ФУНКЦИИ

```

ПРИЛОЖЕНИЕ Г

Свидетельства о регистрации результатов ИД

РОССИЙСКАЯ ФЕДЕРАЦИЯ

**ПАТЕНТ**

НА ПОЛЕЗНУЮ МОДЕЛЬ

№ 222420

**УСТРОЙСТВО МОНИТОРИНГА И
ПРОГНОЗИРОВАНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ В
ЭЛЕКТРО-ЭНЕРГЕТИЧЕСКИХ СИСТЕМАХ НА
ОСНОВЕ НЕЙРОННЫХ СТРУКТУР**

Патентообладатель: *Федеральное государственное автономное образовательное учреждение высшего образования "Южный федеральный университет" (RU)*

Авторы: *Качелаев Олег Вадимович (RU), Полуянович Николай Константинович (RU), Дубляго Марина Николаевна (RU)*

Заявка № **2023126166**

Приоритет полезной модели **12 октября 2023 г.**

Дата государственной регистрации
в Государственном реестре полезных
моделей Российской Федерации **25 декабря 2023 г.**

Срок действия исключительного права
на полезную модель истекает **12 октября 2033 г.**

*Руководитель Федеральной службы
по интеллектуальной собственности*

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат: 429165a10c73823545a195183b73b4aa7
Подпись: **Зубов Юлий Сергеевич**
Действителен с: 18.08.2023 по 02.08.2024

Ю.С. Зубов



РОССИЙСКАЯ ФЕДЕРАЦИЯ



ПАТЕНТ

НА ПОЛЕЗНУЮ МОДЕЛЬ

№ 226794

**ИНТЕЛЛЕКТУАЛЬНОЕ УСТРОЙСТВО
АДАПТИВНОГО ПРОГНОЗИРОВАНИЯ РЕЖИМОВ
ЭНЕРГОПОТРЕБЛЕНИЯ ЭЛЕКТРОСЕТИ**

Патентообладатель: *Федеральное государственное автономное образовательное учреждение высшего образования "Южный федеральный университет" (RU)*

Авторы: *Качелаев Олег Вадимович (RU), Полуянович Николай Константинович (RU), Дубяго Марина Николаевна (RU)*

Заявка № 2024107423

Приоритет полезной модели **21 марта 2024 г.**

Дата государственной регистрации в Государственном реестре полезных моделей Российской Федерации **24 июня 2024 г.**

Срок действия исключительного права на полезную модель истекает **21 марта 2034 г.**

Руководитель Федеральной службы по интеллектуальной собственности

документ подписан электронной подписью
Сертификат 42916540630E33544a195162673b4aa7
Иванова, Юрий Сергеевич
Действителен с 18.07.23 по 02.08.2024

Ю.С. Зубов



ПРИЛОЖЕНИЕ Д

Акты внедрения

УТВЕРЖДАЮ

Проректор по стратегическому развитию и
исследовательской деятельности ФГАОУ ВО
«Южный федеральный университет»

Муханов Е.Л.
2025г.

АКТ

о внедрении в учебный процесс Южного федерального университета результатов диссертационной работы «Разработка метода прогнозирования и управления комплексными энергетическими сетями на основе интеллектуального анализа данных» Качелаева О.В.

Настоящим актом подтверждается внедрение результатов диссертационной работы Качелаева О.В. на тему «Разработка метода прогнозирования и управления комплексными энергетическими сетями на основе интеллектуального анализа данных» в учебный процесс кафедры «Электротехники и мехатроники» Южного федерального университета.

Разработанные: – методы и алгоритмы создания нейросетевых прогностических моделей, на объектно-ориентированном языке программирования Python и в среде программного комплекса моделирования MATLAB, – генетические алгоритмы оптимизации структуры НС-моделей, – подсистемы поддержки принятия решений для управления балансом мощностей в сложных электроэнергетических системах и системах Smart Grid.

Разработки включены в учебный процесс университета дисциплин: «Системы управления энергоснабжением и электрооборудованием», «Системы энергообеспечения, релейная защита и автоматика в системах Smart Grid» и др., по программе подготовки «Интеллектуальные электроэнергетические системы и технологии» направления подготовки магистратуры 13.04.02 «Электротехника и электроэнергетика», где требуется реализовывать практические инструменты по моделированию различных процессов и прогнозированию необходимых параметров в рамках курсовых работ.

Заведующий кафедрой ЭиМ
д.т.н., профессор

Медведев М.Ю.

УТВЕРЖДАЮ

Начальник производственного отделения
«Юго-Западные электрические сети»
филиала ПАО «Россети Юг»-«Ростовэнерго»

В.В. Абрамов

" 2025 г.



АКТ

о внедрении результатов диссертационного исследования
«Разработка метода прогнозирования и управления комплексными энергетическими сетями на
основе интеллектуального анализа данных»
на соискание ученой степени кандидата технических наук
Качелаева Олега Владимовича

Мы, нижеподписавшиеся, главный инженер производственного отделения «Юго-западные электрические сети» филиала ПАО «Россети Юг»-«Ростовэнерго» – Р.В. Леус, заместитель главного инженера - начальник службы распределительных сетей ПО ЮЗЭС - С.Б. Мирошниченко, ведущий инженер службы распределительных сетей ПО ЮЗЭС – Н.О. Терновая, настоящим актом подтверждаем, что в опытную эксплуатацию ЮЗЭС «Ростовэнерго» могут быть внедрены следующие результаты работы Качелаева О.В.:

- метод обработки входных данных для обучения и работы нейросетевой прогностической модели;
- метод и алгоритм прогнозирования и формирования прогностических нейросетевых моделей, позволяющих повысить точность прогноза;
- программный комплекс «СППР», предназначенный для управления прогнозированием объемов электропотребления на различные горизонты, оценку возможных отклонений в потреблении и выводу рекомендаций лицу, принимающему решения (ЛПР).

Эффекты от внедрения диссертационного исследования:

▪ Внедрение разработанного метода обработки входных данных позволяет: анализировать входные данные, поступающие с нижнего уровня SCADA системы, выявляя аномалии и сбои в работе сети и измерительных приборов; использоваться для восстановления отсутствующих данных.

▪ Внедрение разработанного метода и алгоритма формирования прогностических моделей при помощи генетического алгоритма, обеспечивает высокую точность прогнозирования потребления электроэнергии на уровне 96-97% для потребителей с учетом индивидуальных особенностей потребителей ЭЭ.

▪ Внедрение созданного программного комплекса обеспечивает: управление процессами прогнозирования нагрузки и выявления аномалий в потреблении электроэнергии; наглядную визуализацию результатов работы для удобства лица принимающего решения; повышение эффективности управления электропотреблением благодаря составляемому комплексом рекомендациям к действию.

Главный инженер производственного отделения
«Юго-Западные электрические сети»,
Филиал ПАО «Россети Юг»-«Ростовэнерго»

Р.В. Леус

Заместитель главного инженера - начальник
службы распределительных сетей ПО ЮЗЭС

С.Б. Мирошниченко

Ведущий инженер
службы распределительных сетей ПО ЮЗЭС

Н.О. Терновая