

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«НОВОСИБИРСКИЙ ГОСУДАРСТВЕННЫЙ ТЕХНИЧЕСКИЙ
УНИВЕРСИТЕТ»

На правах рукописи



ОСГОНБААТАР ТУВШИН

**РАЗРАБОТКА СИСТЕМЫ ПРЕДИКТИВНОЙ АНАЛИТИКИ
РЕЖИМОВ РАБОТЫ ЭЛЕКТРОЭНЕРГЕТИЧЕСКОЙ СИСТЕМЫ С
ВОЗОБНОВЛЯЕМЫМИ ИСТОЧНИКАМИ
(на примере энергосистемы Монголии)**

Специальность 2.4.3 – Электроэнергетика

Диссертация на соискание ученой
степени кандидата технических наук

Научный руководитель:
доктор технических наук, доцент
Русина Анастасия Георгиевна

Новосибирск 2024

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	4
ГЛАВА 1 ЭЛЕКТРОЭНЕРГЕТИЧЕСКИЕ СИСТЕМЫ, АНАЛИЗ И ПЛАНИРОВАНИЕ ИХ РЕЖИМОВ.....	11
1.1 Вопросы управления режимами электроэнергетических систем.....	11
1.2 Системы управления режимами	13
1.2.1 Методы, используемые в системах управления режимами.....	14
1.2.2 Тенденция развития систем мониторинга и анализа.....	16
1.3 Методы прогнозирования процессов в электрических сетях	19
1.3.1 Классические методы.....	22
1.3.2 Методы машинного обучения.....	27
1.3.3 Ансамблевые методы машинного обучения	30
1.3.4 Метрики погрешности прогнозирования.....	36
1.4 Методы оптимизации режимов электроэнергетических систем.....	38
1.4.1 Общий принцип математической формулировки.....	40
1.4.2 Детерминированные методы оптимизации	42
1.4.3 Стохастические методы оптимизации	46
1.5 Описание энергосистемы Монголии	49
1.5.1 Установленная мощность Центральной энергосистемы	51
1.5.2 Ресурсы возобновляемой энергии	53
1.5.3 Вопросы управления Центральной энергосистемой	56
Выводы по главе 1	58
ГЛАВА 2 РАЗРАБОТКА МЕТОДИКИ ПРОГНОЗИРОВАНИЯ СУТОЧНОГО ГРАФИКА НАГРУЗКИ ДЛЯ ЦЕНТРАЛЬНОЙ ЭНЕРГОСИСТЕМЫ МОНГОЛИИ.....	60
2.1 Задача прогнозирования суточного графика нагрузки ЭЭС	61
2.1.1 Анализ влияния метеофакторов на электропотребление.....	61
2.1.2 Методика, основанная на линейной регрессии.....	64
2.1.3 Применение интегрированной модели авторегрессии ARIMA	73
2.1.4 Применение ансамблевых моделей машинного обучения	76
2.2 Прогнозирование нагрузки в узлах энергосистемы.....	84

2.2.1	Восстановление суточного графика нагрузки в узлах	85
2.2.2	Применение ранговых моделей и результаты.....	87
	Выводы по главе 2.....	91
	ГЛАВА 3 РАЗРАБОТКА МЕТОДОВ ПРОГНОЗИРОВАНИЯ СУТОЧНЫХ ГРАФИКОВ ГЕНЕРАЦИИ ВОЗОБНОВЛЯЕМЫХ ИСТОЧНИКОВ	93
3.1	Вопросы использования возобновляемой энергии	93
3.2	Прогнозирование генерации ветровых электростанций	99
3.2.1	Характеристика генерации ветровых установок	99
3.2.2	Построение ансамблевых моделей и результаты	101
3.3	Прогнозирование генерации солнечных электростанций.....	106
3.3.1	Построение ансамблевых моделей.....	106
3.3.2	Результаты прогнозирования	110
	Выводы по главе 3.....	112
	ГЛАВА 4 ОПТИМИЗАЦИЯ НОРМАЛЬНЫХ РЕЖИМОВ РАБОТЫ ЦЕНТРАЛЬНОЙ ЭНЕРГОСИСТЕМЫ МОНГОЛИИ.....	114
4.1	Решение оптимизационных задач.....	114
4.2	Постановка задачи оптимизации	117
4.2.1	Особенности исследуемого объекта.....	117
4.2.2	Математическая формулировка.....	119
4.3	Методы решения задачи	123
4.3.1	Применение линейного программирования.....	123
4.3.2	Применение метода Ньютона	125
4.4	Результаты оптимизации нормальных режимов работы.....	128
4.4.1	Расчет установившегося режима	129
4.4.2	Распределение активной мощности	131
	Выводы по главе 4.....	137
	ЗАКЛЮЧЕНИЕ	138
	СПИСОК ЛИТЕРАТУРЫ.....	141
	ПРИЛОЖЕНИЕ «А» Параметры, используемые при расчете	159
	ПРИЛОЖЕНИЕ «Б» Акты о внедрении результатов работы	164

ВВЕДЕНИЕ

Актуальность темы исследования. Стратегия развития энергетики Монголии направлена на обеспечение растущей потребности электроэнергии за счет повышения доступности источников и средств передачи энергии, создание единой электроэнергетической системы (ЭЭС) путем интеграции региональных энергосистем, а также участие в межгосударственном объединении электроэнергетики стран Северно-Восточной Азии [1]. Соответственно, во все этапы функционирования ЭЭС стремительно внедряются новые технологии, включая процессы производства, передачи и распределения электроэнергии. Ярким доказательством служит растущая интеграция альтернативных источников, таких как возобновляемые источники энергии (ВИЭ), технологии накопления, которым уделяется особое внимание в настоящее время. Вместе с этим усложняются условия функционирования ЭЭС и необходимо разрабатывать новые методы, методики и средства, повышающие эффективность их работы.

В последнее десятилетие Центральная энергосистема (ЦЭС), где расположена большая часть выработки и потребления электроэнергии в Монголии, приступила к существенной модернизации своей структуры. На данный момент около 84 % электроэнергии вырабатывается на теплоэлектроцентралях (ТЭЦ), остальное – на ВИЭ, таких как ветровые и солнечные электростанции. Благодаря наличию богатых энергоресурсов возобновляемой энергии правительство поставило цель увеличить долю производства электроэнергии от ВИЭ до 30 % к 2030 г. , что способствует сокращению выбросов парниковых газов, связанных с энергетикой. В настоящее время разрабатываются также некоторые проекты угольных электростанций в связи с растущим потреблением электроэнергии. Несмотря на то что возобновляемая энергетика является чистой, имеющей ряд преимуществ, задачи управления режимами работы ЭЭС усложняются ее неопределенностью. Кроме того, переход от традиционной структуры

энергетики к структурам с ВИЭ требует более совершенных и гибких способов управления ЭЭС, в частности, перспективным является использование искусственного интеллекта. Для управления режимами работы ЭЭС, широко используются системы SCADA и WAMS, позволяющие контролировать текущие режимы и создавать базу данных, в которой сохраняется информация о режимах работы оборудования и энергосистемы. Однако совершенствование методологии как прогнозирования, так и планирования режимов работы в краткосрочной перспективе является неотложной практической задачей.

Таким образом, разработка системы предиктивной аналитики нормальных режимов работы ЭЭС с возобновляемыми источниками энергии является актуальной и недостаточно исследованной задачей для ЦЭС Монголии. В диссертационной работе рассматривается задача краткосрочного планирования режимов работы ЭЭС на сутки вперед и возможности ее интеллектуализации.

Степень разработанности темы исследования. Заметный вклад в решение задач планирования режимов работы электроэнергетической системы внесли следующие ученые: Т.А. Филиппова, В.З. Манусов, В.Е. Глазырин, Г.В. Глазырин, Ю.А. Секретарев, Е.В. Цветков, А.Г. Фишов, Н.Я. Ильюшов, П.В. Илюшин, Л.А. Владиславлев, Д.А. Арзамасцев, М.Ш. Мисриханов, П.С. Борщ, Б.И. Аюев, Т.М. Алябышев, В.А. Цурклуков, А.Г. Юркин, Н.В. Абасов, М.Ю. Чернышов, Е.Н. Осипчук, В.М. Горнштейн, В.Г. Журавлев, М.Д. Кучкин, В.И. Обрезков, Т. Abreu, В. Stephen, L. Wang, J. Ching и другие.

Основная часть исследований по этому направлению сосредоточена на задаче планирования, в том числе оптимального распределения активной мощности между электростанциями и их агрегатами, с использованием различных методов оптимизации. В настоящее время, в связи с изменением структуры ЭЭС и требований к управлению ими развитие теории и методов расчета режимов ЭЭС имеют большую актуальность и требуется их

дальнейшее развитие. Перечисленные авторы в своих работах также отмечали, что не существует единой методики, подходящей для всех энергосистем.

Объект исследования. Электроэнергетическая система (ЭЭС) на базе традиционных тепловых электростанций и возобновляемых источников, таких как ветровые и солнечные электростанции (на примере Центральной энергосистемы Монголии).

Предмет исследования. Оптимальное планирование режимов работы ЭЭС с учетом ВИЭ при составлении краткосрочных балансов (на суточном интервале) электрической энергии.

Цель диссертационной работы. Создание системы аналитики, позволяющей решать оптимизационные задачи и выполненной на основе математических моделей и алгоритмов для решения прикладных задач планирования и анализа режимов ЭЭС с возобновляемыми источниками.

Задачи исследования.

1. Анализ существующих методов планирования режимов работы ЭЭС в краткосрочной перспективе, в том числе прогнозирование и оптимизация.
2. Разработка комплексной математической модели суммарного графика нагрузки и его составляющих по узлам ЭЭС на основе комбинирования статистических методов и методов машинного обучения.
3. Разработка алгоритма и математической модели суточного графика генерации ВИЭ, таких как солнечные и ветровые электростанции, с помощью ансамблевых моделей машинного обучения.
4. Разработка алгоритмов оптимизации нормальных режимов работы ЭЭС, обеспечивающих распределение активной мощности между ТЭЦ с учетом прогноза нагрузки ЭЭС и генерации ВИЭ.
5. Формирование концепции системы предиктивной аналитики режимов работы ЭЭС с ВИЭ.

Методы исследования. При решении поставленных задач

прогнозирования временных рядов использовались статистические методы, включая линейную регрессию и интегрированную модель авторегрессии и скользящего среднего, а также ансамблевые модели машинного обучения. Оптимизационная задача решена методами линейного программирования и Ньютона второго порядка. Программная реализация выполнена на языке программирования *Python*. Экспериментальное исследование и тестирование алгоритмов оптимизации выполнено средствами программного продукта *RastrWin.3.0*.

Научная новизна диссертации. В результате исследований получены следующие научные результаты:

1. Разработаны математические модели электропотребления ЭЭС и ее узлов, основанные на комбинации ансамблевых моделей машинного обучения и статистических ранговых моделей.

2. Разработаны методики прогнозирования суточного графика генерации ВИЭ, таких как солнечные и ветровые электростанции, основанные на ансамблевых моделях и учитывающие метеорологические условия и информацию о сезонности.

3. Разработаны алгоритмы оптимизации нормальных режимов работы ЦЭС Монголии с учетом моделей электропотребления и генерации источников электроэнергии.

4. Впервые в концепцию системы предиктивной аналитики режимов работы ЭЭС включены такие программные модули, как прогнозирования электропотребления и генерации ВИЭ, а также оптимизации нормальных режимов работы ЦЭС Монголии.

Теоретическая и практическая значимость работы. Предложена концепция создания системы предиктивной аналитики режимов работы ЭЭС с ВИЭ, которая включает в себя следующие программные продукты.

1. Программа краткосрочного прогнозирования графиков нагрузки в узлах ЭЭС на основе ансамблевых моделей машинного обучения и рангового анализа, позволяющая автоматизировать предсказания и снизить их

погрешность.

2. Программа прогнозирования генерации ВИЭ для ЭЭС Монголии, позволяющая оценить потенциалы ВИЭ и учесть их неопределенность при планировании режимов ЭЭС.

3. Программа оптимизации нормальных режимов работы ЭЭС за счет планирования графиков генерации ТЭЦ, позволяющая повысить эффективность работы ЭЭС в целом.

На все указанные программы получены свидетельства о государственной регистрации разработанных автором программ для ЭВМ. Программные продукты также использованы при формировании отчета «Технические рекомендации по интеграции гидроаккумулирующих электростанций мощностью 250 МВт в центральную энергосистему Монголии».

Результаты, полученные в диссертационной работе, обсуждались на технических совещаниях ОАО «Национальный диспетчерский центр Монголии» и Ассоциации производителей возобновляемой энергии Монголии, а также внедрены в учебный процесс Новосибирского государственного технического университета (НГТУ): материалы используются при чтении лекций и проведении лабораторных работ по курсу «Электроэнергетические системы и управления ими» и при выполнении выпускных квалификационных работ.

Положения выносимые на защиту.

1. Предложенные временные ряды процессов в многофакторных моделях позволяют эффективно прогнозировать нагрузки ЭЭС и ее узлов, а также генерации ВИЭ, снижая погрешность до 1,25 % для электропотребления, и до 9,0 % для генерации ВИЭ (на примере ЦЭС Монголии).

2. Предложенные алгоритмы оптимизации нормальных режимов ЭЭС повышают ее эффективность по потерям в сети на 2 % или по средней цене закупки у ТЭЦ на 4 % (в зависимости от того, какой критерий принят при

оптимизации) за счет перераспределения активной мощности между ТЭЦ с учетом генерации ВИЭ.

3. Предложенная концепция системы предиктивной аналитики позволяет создавать единые наборы программных средств для проведения серий имитационных расчетов и принятия решений по мониторингу, контролю и планированию нормальных режимов ЭЭС с ВИЭ.

Степень достоверности. Научные положения, выводы и рекомендации, изложенные в диссертационной работе, обоснованы приведенными теоретическими положениями и результатами, полученными при проведении экспериментальных расчетов для реальной энергосистемы. Достоверность проведенных исследований подтверждена сравнением результатов применения статистических методов и методов машинного обучения и корректным использованием средств программного обеспечения (*RastrWin3, Pandapower*).

Апробация результатов. Основные положения диссертации и ее частей, а также результаты исследований представлялись и обсуждались на следующих конференциях и семинарах, а именно:

- IEEE International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON), (г. Екатеринбург, УрФУ), в 2022 г.;
- IEEE International Conference on Problems of Informatics, Electronics and Radio Engineering (PIERE), (г. Новосибирск, НГТУ), в 2022 г.;
- XVI Всероссийская научная конференция молодых ученых «Наука Технологии Инновации» (г. Новосибирск, НГТУ), в 2022 г.;
- IEEE Belarusian–Ural–Siberian Smart Energy Conference (BUSSEC), (г. Екатеринбург, УрФУ), в 2023 г.;
- IEEE International Conference of Young Professionals in Electron Devices and Materials (EDM), (Алтай), в 2024 г.

Публикации. По теме диссертации опубликовано 11 печатных работ, в том числе 4 научные статьи в рецензируемых научных изданиях, включенных в перечень ВАК РФ; 5 статей, входящих в наукометрическую

базу «Scopus»; 1 статья в сборнике научных трудов всероссийских конференций; 1 статья в прочих журналах. Получено 3 свидетельства о государственной регистрации программ для ЭВМ.

Личный вклад автора диссертации. Автором совместно с научным руководителем выполнена постановка целей и задач исследования. Разработка математических моделей и алгоритмов, их программная реализация выполнены автором в соответствии с рекомендациями. В работах, опубликованных в соавторстве, автору принадлежит формализация поставленных задач исследований, выбор методов их решения, проведение исследований, анализ и обобщение результатов.

Структура и объем диссертации. Диссертационная работа состоит из введения, четырех глав, заключения, списка литературы, состоящего из 145 наименований, и 2 приложений. Общий объем диссертации составляет 166 страниц, включая 24 таблицы и 52 рисунков.

ГЛАВА 1 ЭЛЕКТРОЭНЕРГЕТИЧЕСКИЕ СИСТЕМЫ, АНАЛИЗ И ПЛАНИРОВАНИЕ ИХ РЕЖИМОВ

Настоящее диссертационное исследование посвящено управлению режимами работы электроэнергетической системы (ЭЭС), использующей возобновляемые источники энергии (ВИЭ), на суточном интервале. В соответствии с этим, основное внимание уделено планированию режимов работы на сутки вперед. Планирование режимов работы электроэнергетических систем и энергообъектов является одной из основных задач, позволяющих обеспечить баланс мощности и показателей качества энергосистемы. В основе планирования режимов работы лежит прогнозирование ожидаемых процессов и соответствующая оптимизация режимов работы. Задачи прогнозирования процессов и их оптимизации являются неотъемлемой частью управления режимами работы энергосистемы. В настоящей главе рассмотрены методы решения таких задач в краткосрочной перспективе.

1.1 Вопросы управления режимами электроэнергетических систем

Электроэнергетическая система (ЭЭС) является сложным объектом, включающим множество структурных элементов, связанных между собой электрическими сетями [2]. Электроэнергетический режим – это состояние работы ЭЭС, характеризующееся определенными параметрами, такими как напряжение, частота, мощность и другие показатели, которые обеспечивают стабильное и надежное электроснабжение потребителей. Изменение параметров в любых структурных единицах влияет на режимы работы всей ЭЭС. Принимая во внимание этот факт, можно сказать, что режим является общим и взаимозависимым для всей ЭЭС. Разумеется, при рассмотрении любых параметров в части ее структуры необходимо учитывать их влияние электроэнергетическую систему в целом. Таким образом, управление

режимами работы электроэнергетической системы остается сложной и комплексной задачей, требующей одновременного учета всех ее объектов, начиная от источников и заканчивая потребителями электроэнергии.

Имеется большое количество публикаций и работ по тематике управления режимами электроэнергетической системы таких авторов, как В.З. Манусова, Т.А. Филипповой, В.Г. Журавлева, А.Г. Фишова, Д.А. Арзамасцева, П.И. Бартоломея, В.А. Веникова, А.З. Гамма, О.Т. Гераскина, В.М. Горнштейна, В.И. Идельчика, Л.А. Крумма, И.М. Марковича, Е.В. Цветкова, А.Г. Русиной, П.В. Матренина, А.И. Хальясмаа, С.А. Ерошенко, Н.М. Merrill, В. W. Erickson, F.C. Schweppe, M.C. Caramanis и других. Предложенные этими авторами методологии не потеряли своего значения, и стали базой для решения задач в современных условиях. В основном эти работы дают также научную основу и методологию для создания систем предиктивной аналитики режимов работы ЭЭС.

В настоящее время теория, методология и принципы управления электроэнергетикой рассматриваются с позиций крупнейших энергетических систем и в энергетической науке появилось самостоятельное направление – теория управления энергетикой. Однако многие выдающиеся исследователи-энергетики утверждают, что не существуют единой теории и методологии управления энергетическими системами. Под термином «теория управления» понимаются научно-технические основы, решающие определенные виды задач для системы с конкретными свойствами [70]. В целом основная задача управления режимами работы ЭЭС включает в себя определение и реализацию комплекса мер и действий, направленных на обеспечение стабильности и надежности работы системы, а также эффективного использования ресурсов и минимизации затрат на производство и потребление электроэнергии.

При управлении режимами работы ЭЭС необходимо решать ряд сложных задач, для чего необходима обработка большого объема данных и применения различных математических методов, с учетом

продолжительности воздействий и целей управления. В связи с этим имеется необходимость классификации таких задач на следующие три основные иерархические группы: ситуативная, в пространстве и во времени [2, 3, 4]. В случае ситуационной иерархии принятие решений различных оперативных задач определяется в зависимости от таких состояний системы, как нормальное, утяжеленное и аварийное [5]. Иерархии в пространстве позволяют управлять территориально распределенными объектами энергетики как единым целым. В описанных выше случаях речь идет о реализации управления текущими режимами работы ЭЭС. Отличие иерархии во времени состоит в том, что она позволяет разделять задачи планирования режимов для разных временных рядов на основе ретроспективных данных [2].

На практике вопрос управления режимами ЭЭС часто решается с использованием специальных устройств, обладающих многофункциональными возможностями, состоящих из комплекса систем контроля, средств диспетчерского и автоматического управления, а также мониторинга. В целом под такими специальными устройствами можно понимать систему, осуществляющую анализ режимов работы ЭЭС с программной поддержкой.

1.2 Системы управления режимами

Системы управления режимами ЭЭС являются специализированными программными средствами, позволяющими анализировать режимы системы, выявлять аномалии и предсказывать ее состояние в будущем. Эти системы позволяют осуществлять визуальный контроль и анализ режимных параметров, таких как мощность, напряжение, переток и другие показатели электроэнергии. В них могут использоваться данные, собранные как от системы диспетчерского управления, так и от многочисленных измерительных и контрольных приборов, установленных в узлах ЭЭС.

Обрабатываются полученные данные с применением различных методов и алгоритмов их анализа для установления закономерностей и тенденций. В результате обработки данных формируются аналитические отчеты и прогнозы, которые могут быть использованы диспетчерским персоналом для принятия решений, предотвращения аварийных ситуаций и повышения эффективности энергосистемы. Системы управления позволяют также представлять данные в виде графиков, диаграмм и других визуальных решений, что помогает их анализировать. Это помогает операторам системы принимать своевременные решения для обеспечения стабильности и надежности работы системы.

1.2.1 Методы, используемые в системах управления режимами

В системах управления может использоваться множество созданных и усовершенствованных математических моделей и методов для решения задач расчёта нормальных и переходных режимов ЭЭС, оптимального управления ими и обеспечения надежности, оценки состояния электроэнергетических систем [6–9].

1. Методы статистического анализа [8]: Эти методы используются для установления статистических закономерностей в данных о поведении системы. К ним относятся расчеты средних отклонений, корреляций и других статистических показателей. Применяется также анализ временных рядов, включая методы сглаживания, декомпозиции временных рядов и прогнозирования.

2. Машинное обучение [9, 10]: Методы машинного обучения позволяют системе обучаться на основе исторических данных и использовать полученные модели для предсказания состояния в будущем. Они обладают способностью обрабатывать крупномасштабные данные, а также выполнять классификацию, регрессию, кластеризацию и другие функции.

3. Искусственный интеллект [11, 12]: В этом разделе используются

модели, имитирующие человеческое и природное мышление. Методы искусственного интеллекта включают в себя нейронные сети, генетические алгоритмы, алгоритм имитации отжига и другие алгоритмы.

4. Оптимизационные методы [13–22] позволяют оптимизировать режим работы ЭЭС с учетом необходимых ограничений и заданных критериев. Примерами являются линейное и нелинейное программирование, генетические алгоритмы и другие стохастические методы.

Перечисленные выше группы методов представляют собой лишь некоторые из тех, которые могут быть использованы в системах мониторинга и анализа режимов работы ЭЭС. В зависимости от особенностей системы и заданных требований подбираются конкретные методы. Комбинация этих методов позволяет системам управления режимами работы ЭЭС обрабатывать большие объемы данных, выявлять неисправности и прогнозировать будущее состояние системы. На практике широкое распространение получили следующие основные системы, созданные на базе изложенных выше методов:

1. *SCADA (Supervisory Control and Data Acquisition)* [23, 24] – система, позволяющая контролировать состояние электроэнергетической системы и управлять текущими режимами в реальном времени. Система собирает данные о состоянии структурных элементов ЭЭС, таких как генераторы, трансформаторы, воздушные линии, выключатели и другие виды оборудования, и предоставляет системным операторам текущую информацию о состоянии ЭЭС. Такая система обеспечивает принятие решений и выполнение действий, направленных на поддержание стабильности и надежности ЭЭС.

2. *EMS (Energy Management System)* [24, 25] является системой, объединяющей различные функции мониторинга, анализа и управления. Система *EMS* направлена на оптимизацию процессов производства, передачи и распределения электроэнергии, с учетом необходимых факторов, таких, как спрос, цены на энергию, доступность ресурсов и другие. Эта система

используется при анализе данных, прогнозировании потребления и оптимизации работы ЭЭС для достижения максимальной эффективности.

3. *AMI (Advanced Metering Infrastructure)* [7] – инфраструктура передачи данных об электропотреблении, позволяющая собирать информацию от интеллектуальных счетчиков потребителей и передавать ее на центральный сервер для анализа. Система *AMI* проводит подробный анализ электропотребления и выявляет такие проблемы, как утечки энергии или неисправности в ЭЭС, а также принимает меры по оптимизации потребления.

4. *DMS (Distribution Management System)* [26, 27] – система управления распределительной сетью, которая позволяет контролировать и управлять электросетевым оборудованием, таким как трансформаторы, переключатели, автоматические выключатели и другие. *DMS* выполняет анализ данных о положении коммутационного оборудования сетей и принимает решения по эксплуатации и техническому обслуживанию. С помощью аналитических систем типа *DMS* можно оптимизировать схему распределительной сети, улучшить качество поставляемой энергии и повысить надежность энергоснабжения.

5. *PAS (Predictive Analytic System)* [8, 28, 29] является аналитической системой, использующей исторические данные и текущие состояния ЭЭС для прогнозирования процессов и тенденций в будущем. С помощью этой системы могут осуществляться прогнозы электропотребления, выработки возобновляемой энергии и других процессов.

1.2.2 Тенденция развития систем мониторинга и анализа

За последние 10...15 лет в мире значительно повысился интерес к вопросам создания высокоэффективных и высоконадежных систем оперативно-диспетчерского управления и обработки больших объемов данных. С одной стороны, это тесно связано со стремительным развитием в

области интеллектуализации, что повышает потенциал и расширяет масштабы применения автоматизированных систем. С другой стороны, развитие ЭЭС требует более перспективных и совершенных технологий управления ею. Более того, такие системы постоянно требуют совершенствования и развития в связи с модификацией ЭЭС.

На данный момент крупнейшие компании в энергетической отрасли, такие как *Schneider Electric*, *ABB*, *GE Digital*, *Siemens*, *IBM*, *SAP*, *PSI Software AG* занимаются разработкой новых проектов по внедрению перспективных технологий управления ЭЭС на базе цифровизации [30].

PSI Software AG – немецкая компания по разработке программного обеспечения АСУ, основанная в 1969 г. В течение последних 20 лет она сумела занять доминирующее положение на рынках Германии, Австрии и Швейцарии, где работают такие гиганты, как *Siemens* и *ABB*. На сегодняшний день успешно внедрено более 200 проектов в 27 странах Европы и Азии. Основным продуктом этой компании является система *PSIcontrol*, объединяющая множество функций, таких как *SCADA*, *EMS*, *АСЧМ / LFS*, *GIS* и тренажерная система *DTS*.

Заметным продуктом на рынке систем *SCADA/EMS* является пакет программного обеспечения *Siemens Spectrum Power*[™], представляющий собой комплекс инновационных программных решений компании *Siemens*. Система позволяет информационно связывать ЭЭС любого размера и обеспечивать их централизованное управление. *Siemens Spectrum Power* используется во многих странах, включая США, Канаду, Великобританию, Германию, Францию, Испанию, Италию, Индию, Бразилию, Южную Африку и страны Азии. В системе реализован ряд функций, в том числе управление энергосистемой и ее резервами, прогнозирование электропотребления, интеграцию ВИЭ, автоматизацию и оптимизацию процессов.

С 1878 г. отсчитывается история компании *General Electric*, основанной Томасом Эдисоном. Сегодня компания *GE Digital Grid*, являющаяся подразделением корпорации *General Electric*, накопила большой

опыт реализации *SCADA/EMS* проектов по всему миру. Одним из проектов стало долгосрочное сотрудничество с одним из крупных операторов и рынков электроэнергии в мире – *Midcontinent Independent System Operator (MISO)*, управляющим электросетями в 16 штатах США и Канады. Стоит отметить, что она также играет выдающуюся роль в отрасли разработки более совершенных технологий, таких как система мониторинга переходных режимов (СМНР), использующая технологию синхронных векторных измерений *WAMS*.

Реализация таких систем управления привела к следующим основным технологическим изменениям в электроэнергетике [25]:

- переход от жесткого оперативно-диспетчерского управления к более гибкому и адаптивному уровню;
- создание высокоэффективной информационно-вычислительной базы как основной составляющей электроэнергетической системы;
- использование распределенных интеллектуальных систем управления и аналитических инструментов для поддержки энергоэффективности и реализации решений в режиме реального времени;
- создание системы нового поколения (*SCADA*, *EMS*, *WAMS*), реализующей современные алгоритмы и методы управления энергосистемой, включая ее структурные элементы.

Анализ представленных проектов и публикаций в этой отрасли показывает общие тенденции в развитии систем управления энергосистемами, суть которых заключается в цифровизации и интеллектуализации энергетики. Идея и цель разработчиков системы состоит также в создании новой модели энергосистем и рынка электроэнергии, отвечающей перспективным проблемам будущего.

Настоящее диссертационное исследование направлено на управление режимами в краткосрочном периоде, а именно на суточном интервале. Решение задачи краткосрочного планирования является фундаментальной базой оперативно-диспетчерского управления, влияющего на технико-

экономические показатели ЭЭС. Исходя из этого, принято решение уделить основное внимание указанному направлению, которое является одной из главных функций управления режимами работы ЭЭС. Планирование часто может осуществляться путем выполнения прогнозных вычислений с допустимой погрешностью и непрерывной оптимизацией по определенным критериям. Иными словами, планирование выполняется таким образом, чтобы принять оптимальное решение на основе предсказаний состояния процессов, происходящих в ЭЭС.

1.3 Методы прогнозирования процессов в электрических сетях

Предиктивный анализ любого процесса в энергосистеме является существенной частью управления режимами, в частности планирования. Этот анализ включает в себя элементы прогнозирования состояния какого-либо процесса в будущем на основе статистических данных или опыта. В настоящее время актуальными задачами становятся прогнозирование потребления электроэнергии и прогнозирование выработки возобновляемых источников энергии.

Зарождение современной теории планирования и прогнозирования относится к началу 20-х годов прошлого столетия. Сущность этой теории заключалась в полном отождествлении плана и прогноза. Следует отметить, что в те годы методология прогноза только формировалась. Прогнозный подход требует анализа всей совокупности хозяйственных явлений как прошлого так и настоящего, а также вероятности этих событий в будущем. В отрасли энергетики первые работы в этой области относятся к 1960-м годам, когда была опубликована первая статья по прогнозированию нагрузки [31]. В развитии теории прогнозирования исследователи выделяют несколько основных временных этапов [32]:

- 1) 1950-е годы – начало прогностических исследований, развитие и использование теории прогнозирования и простых прогнозных моделей;

2) 1960...1970 годы – «бум прогнозирования», в ходе которого разработано большинство теоретических вопросов, предложены новые методы, созданы сложные прогнозные модели, широкое применение получило и прогнозирование с использованием ЭВМ;

3) с конца 1970-х – начала 1980-х годов – развитие теории вероятностей и статистики, создание различных моделей прогнозирования (например, временные ряды, регрессионный анализ) и появление компьютерных технологий позволило значительно улучшить методы обработки данных.

Наиболее обобщенные подходы к решению различных задач моделирования и прогнозирования временных рядов представлены в работах Т.А. Филипповой, В.З. Манусова, Н.Б. Овсянникова, Б.И. Аюева, И.Е. Васильева, А.С. Бердина, П.И. Бартоломея, М.А. Рабиновича, В.И. Богданова, И.А. Соловьевой, М.А. Короткевича, В.В. Курачинского, А.Г. Русиной, П.В. Матренина, А.В. Пичуева, а также зарубежных ученых, таких как: E.D. Farmer, D.W. Bunn, P.C. Gupta, G.B. Ackerman, A.V. Baker и др. Сейчас в новых условиях теория и методы прогнозирования требуют дальнейшего развития и приобрели большую актуальность. В настоящее время во многих энергосистемах ведется работа по усовершенствованию существующих методов с учетом современных требований и возможностей современной компьютерной базы.

В работах многих ученых [33–45] описаны методики, позволяющие прогнозировать процессы в ЭЭС. Согласно проведенным исследованиям, методы можно классифицировать на две главные категории: традиционные (классические) и методы искусственного интеллекта, основанные на машинном обучении. Первый класс методов не теряет своей значимости до настоящего времени [46]. Эти методы имеют несколько ключевых преимуществ: скорость вычислений, простота реализации, требования к данным и интерпретируемость. Недостатками являются низкая эффективность при рассмотрении нелинейности, ограниченная гибкость,

игнорирование внешних факторов, сложности с многомерными данными и недостаток автоматизации.

Сегодня, с развитием технологий и увеличением объемов данных, методы, основанные на машинном обучении и искусственном интеллекте, становятся все более популярными и эффективными. Имеются различные методы этого подхода, например, метод опорных векторов [47–49], нечеткая логика [40, 50–52], нейронные сети [53–56] и гибридные или ансамблевые модели [54, 57]. По сравнению с классическими методами, методы машинного обучения имеют более гибкую структуру и могут учесть множество факторов, влияющие на временные ряды. Но процесс их реализации достаточно сложен [57].

Горизонт прогнозирования определяет природу процессов. Каждый временной горизонт требует специфического подхода к прогнозированию, учитывающего уникальные характеристики процессов [46]. На практике методология прогнозирования классифицируется по времени: до 1 дня для краткосрочных прогнозов нагрузки, от 1 дня до 1 года для среднесрочных прогнозов нагрузки и от 1 до 10 лет – для долгосрочных прогнозов. На долгосрочной прогноз существенное влияние оказывают факторы макросреды, в том числе экономика государства, социальные условия, состояние техники и цена на ископаемые энергоносители. Годовой или среднесрочный прогноз зависит от микросреды в отрасли. Для краткосрочного прогноза главное значение имеют внутренние факторы процессов и внешние, влияющие на них.

В целом можно сказать, что краткосрочное прогнозирование процессов сложнее других горизонтов, так как оно учитывает стохастические и хаотические факторы. В данной главе рассматривается краткосрочное прогнозирование, которое является важнейшей задачей функционирования энергосистемы.

1.3.1 Классические методы

Классические методы прогнозирования, такие как временные ряды, экспоненциальное сглаживание и регрессионный анализ, были широко использованы в прошлом для прогнозирования событий на основе исторических данных. Однако эти методы имеют свои недостатки, например, ограниченную возможность учёта сложных взаимосвязей данных и предсказания нелинейных трендов. Тем не менее, классические методы прогнозирования всё-таки могут быть полезными в определенных ситуациях и для определенных типов данных. Например, они могут быть полезны для прогнозирования временных рядов с явными сезонными или циклическими паттернами, а также для моделирования линейных взаимосвязей в данных [35, 58-61]. Таким образом, классические методы прогнозирования остаются важным инструментом в анализе данных.

Регрессионный анализ. Основной целью регрессионного анализа является нахождение взаимосвязей между зависимой переменной, или функцией отклика, и одной или несколькими другими переменными, называемыми независимыми или воздействующими факторами. Эта связь выражается в виде математической модели, называемой уравнением регрессии. Другими словами, существует некоторая зависимость между переменными X и Y , которая определяется следующим уравнением:

$$M\left(\frac{Y}{X}\right) = f(x); \quad (1.1)$$

где $M\left(\frac{Y}{X}\right)$ – условное математическое ожидание Y при фиксированном значении x .

Линейная регрессия – Самый распространенный вид регрессионного анализа. Этот вид анализа позволяет определить линейные связи между исследуемым процессом y_i и внешним фактором x_i . Ограничением в использовании линейной регрессии является рассмотрение только линейных зависимостей между исследуемым процессом и внешним фактором, которые

выражаются следующим образом:

$$y_i = ax_i + b + \varepsilon_i; \quad (1.2)$$

где $i = 1, 2, \dots, n$ – множество наблюдений исследуемого процесса y_i и внешнего фактора x_i ; a – коэффициент регрессии; b – константа уравнения; ε – ошибка наблюдений.

В дополнение к линейной регрессии, нелинейные модели, включая квадратичные, экспоненциальные и логистические функции, также используются при учете внешних признаков в задачах прогнозирования. Наличие физической связи между рассматриваемыми переменными, например, связи «потребление электроэнергии - температура воздуха», «потери в сети - реактивная мощность» и «потери в сети - активная мощность», позволяет применить регрессионный анализ.

Авторегрессионные модели часто используются в задаче краткосрочного прогнозирования любого временного ряда. В модели авторегрессии предполагается, что значение прогноза определяется линейной функцией нескольких предыдущих значений исходного временного ряда и случайных составляющих. Эта модель состоит из следующих компонентов:

- Авторегрессионная модель (AR), определяющая линейную функцию, описывается следующим выражением:

$$y_t = c + \sum_{i=1}^p a_i y_{t-i}; \quad (1.3)$$

где y_t – фактическое значение; a – коэффициент авторегрессии; c – постоянная константа уравнения (часто для упрощения предполагается равной нулю); $i = 1, 2, 3, \dots, p$ – порядок полинома авторегрессии.

Цель сглаживания состоит в выделении основной тенденции временного ряда и исключении случайных колебаний. Наиболее часто используемыми методами сглаживания является скользящее среднее (*Moving average, MA*) и экспоненциальное скользящее среднее (*Exponential smoothing, ES*). Самым простейшим методом является скользящее среднее. Модель скользящего среднего (*Moving average, MA*) описывается следующим:

$$u_t = \sum_{j=1}^q \beta_j u_{t-j} ; \quad (1.4)$$

где u_t – значение случайной погрешности; β – значение весового коэффициента; $j = 1, 2, 3, \dots, q$ – порядок полинома скользящего среднего.

Модель авторегрессии со скользящим средним (*autoregressive moving average, ARMA*) включает в себе части авторегрессии (*AR*) порядка p и скользящего среднего (*MA*) порядка q . Модель *ARMA* (p, q) с порядками p и q определяется следующим уравнением:

$$y_t = c + \sum_{i=1}^p a_i y_{t-i} + \sum_{j=1}^q \beta_j u_{t-j} ; \quad (1.5)$$

где y_t – фактическое значение; a – коэффициент авторегрессии; β – коэффициент сглаживания; c – постоянная константа уравнения (часто для упрощения предполагается равной нулю); u_t – значение случайной погрешности; $i = 1, 2, 3, \dots, p$ – порядок полинома авторегрессии.; $j = 1, 2, 3, \dots, q$ – порядок полинома скользящего среднего.

Данная модель используется для анализа и прогнозирования стационарных временных рядов. Если временной ряд характеризуется нестационарным процессом, то необходимо привести его к стационарному виду для создания данной модели. Для преобразования к стационарному ряду, применяются три метода, включая удаление тренда, сезонность и дифференцирование. На практике часто используется метод дифференцирования, который описывается следующим уравнением:

$$y'_t = y_t - y_{t-1} ; \quad (1.6)$$

где y'_t – преобразованное значение; y_t – истинное значение временного ряда.

Интегрированная модель авторегрессии и скользящего среднего (*autoregressive integrated moving average, ARIMA*) часто используется в задаче краткосрочного прогнозирования, которая является самым перспективным методом, и играет значительную роль в развитии методологии прогнозирования процессов в электроэнергетических сетях. Для построения

данной модели *ARIMA* необходимо определить весовые коэффициенты (α и β) и порядок (p, d и q). Порядки полинома (p и q) определяются функцией автокорреляции (*ACF*) и функцией частичной автокорреляции (*PACF*). Значение d выражается количеством разностно-стационарного или интегрированного процесса. При построении модели необходимо стремиться к минимизации числа ее параметров. Для определения весовых коэффициентов используются такие методы, как метод наименьших квадратов и метод максимального правдоподобия.

Преимущества этой модели заключается в простоте и прозрачности анализа и моделирования временного ряда. Недостатком является ограниченная возможность учета дополнительных переменных, в том числе метеорологических факторов, при прогнозировании многофакторных временных рядов.

Метод ранговых моделей. Большинство исследований, посвященных прогнозированию электропотребления, направлены на разработку методики для всей ЭЭС или отдельных узлов, обеспечивающих электроэнергией крупный объект. Однако задаче прогнозирования нагрузки в узлах ЭЭС уделяется сравнительно мало внимания [62]. Разработка и совершенствование методологии для решения этой задачи становятся неотложными как для планирования режимов, так и для проектирования ЭЭС [63].

В работе [64] предлагается два технических решения для прогнозирования энергопотребления ЭЭС на основе модели авторегрессии. Вначале были спрогнозированы суточные графики нагрузки для каждого узла, а затем, объединив полученные графики, был построен суточный график нагрузки ЭЭС. Второе решение: суточный график нагрузки ЭЭС прогнозируется по модели авторегрессии, а нагрузки в узлах формируются в результате умножения на коэффициент участия каждого узла в общем нагрузке ЭЭС.

В работах [65, 66] методы машинного обучения используются для

построения моделей потребления электроэнергии как в целом по ЭЭС, так и по ее узлам. Основная идея авторов заключается в определении коэффициента участия каждого узла, на основе которого строятся модели нагрузки в узлах ЭЭС.

В работах [67-70] авторы используют искусственные нейронные сети в задачах прогнозирования энергопотребления на уровне как ЭЭС, так и ее подстанций. Прогнозирование нагрузки каждого узла осуществлялось так же, как и прогнозирование нагрузки ЭЭС, но отличалось тем, что учитывался коэффициент участия соответствующих подстанций. На основе информации о нагрузке ЭЭС и ее узлов, а также внешних факторах, таких как метеорологические и календарные признаки, была решена поставленная задача прогнозирования.

Авторы работ [71, 72] провели эксперименты на данных электропотребления в 22 узлах. В результате анализа были разработаны модели, базирующиеся на следующих методах: математическая пропорция, линейная и авторегрессия (ARIMA), а также нейронные сети. В задаче моделирования суточного графика нагрузки в узлах достаточной эффективностью обладает метод математической пропорции, содержащий коэффициент участия узла.

Согласно мнению авторов вышеупомянутых работ, при прогнозировании нагрузки в узлах следует учитывать коэффициент, который отражает долю электропотребления каждым узлом. В этих исследованиях также подчеркивается положительное влияние использования данного коэффициента. Ранговые модели, основанные на этих коэффициентах, легко реализуются, поскольку не требуют значительных объемов исторических и вычислительных данных для каждого узла. Таким образом, ранговые модели позволяют прогнозировать структурные свойства объектов. Такие задачи достаточно распространены при расчете режимов и их оптимизации.

Если энергетическая система имеет иерархическую структуру с несколькими элементами, различающимися по уровню потребления энергии,

то можно использовать ранговые модели. Ранг может быть вычислен в относительных единицах для любых узлов, таких как подстанции, регионы снабжения электроэнергией, электростанции и другие элементы системы. Определение ранга осуществляется следующим образом:

$$R_i = \frac{Y_i}{Y_{\Sigma}} ; \quad (1.7)$$

при

$$Y_{\Sigma} = \sum_{i=1}^n Y_i ; \quad (1.8)$$

где Y_i – параметр прогноза для i -ой части, Y_{Σ} – общая величина для исследуемого объекта, R_i – коэффициент ранга, n – количество частей.

Зная значение суммарной нагрузки, можно распределить её по узлам с помощью ранговых коэффициентов.

$$Y_i = \hat{Y} \cdot R_i ; \quad (1.9)$$

где $\hat{Y}$ – прогнозируемое значение параметра прогноза для всех объектов, R_i – коэффициент ранга, Y_i – прогнозируемое значение i -го узла.

Если ранг остается неизменным на протяжении различных временных интервалов, то ранговые модели могут быть интегрированы с другими подходами для построения модели временных рядов в каждом узле. В противном случае следует рассчитывать коэффициенты ранга для разных временных периодов.

1.3.2 Методы машинного обучения

На данный момент проведено множество исследований, связанных с задачами прогнозирования временных рядов, и создано большое количество моделей с целью минимизации погрешности прогнозирования. В энергетике методы искусственного интеллекта, называемые машинным обучением, получили довольно широкое распространение [73]. Эти методы, в том числе метод опорных векторов, нечеткая логика, искусственные нейронные сети и

глубокое обучение, имеют более гибкое свойство и обладают высокой точностью, чем традиционные. Они также позволяют создавать модели, способные улавливать сложные взаимосвязи в переменных.

Метод опорных векторов (*Support Vector Machines, SVM*) – это мощный и широко используемый алгоритм машинного обучения, применяемый для задач классификации и регрессии. Этот алгоритм находит гиперплоскость (или несколько гиперплоскостей в многомерном пространстве), максимально разделяющую классы признаков. Иначе говоря, идея опорных векторов состоит в том, чтобы найти такую разделяющую гиперплоскость, которая максимально удалена от ближайших объектов обучающей выборки, называемых опорными векторами.

В работе [74] предложен алгоритм опорных векторов и поставлена задача анализа и обработки больших данных для получения точных моделей потребления электроэнергии в северной части Китая. Авторы используют интегрированную модель авторегрессии и скользящего среднего (*ARIMA*) с целью преобразования исходных данных из нелинейной зависимости в линейную. На основе преобразованных данных и сезонных факторов, полученных методом опорных векторов, осуществляется прогнозирование потребления электроэнергии.

Нечеткая логика (*Fuzzy logic, FL*) – это математическая теория, позволяющая моделировать нечеткие и неопределенные концепции в системах управления и принятия решений. Широко применяется в задачах энергетики, таких как прогнозирование временного ряда, системное планирование, управление системой и стабильность энергосистемы. В нечеткой логике каждая переменная, влияющая на процесс, может принимать значение от 0 до 1, которое характеризует степень принадлежности к определенному множеству. Например, вместо того, чтобы говорить, что температура в комнате истинно высокая или ложно низкая, мы можем использовать нечеткие значения, такие как «немного высокая» или «очень низкая». Этот метод также часто применяется в сочетании с методами

машинного обучения.

В работе [75] авторы прогнозировали суточные графики нагрузки с учетом метеорологических и календарных признаков, включая температуру наружного воздуха, тип дня и времени года в Турции. В исследовании вспомогательную роль для нейронных сетей послужила нечеткая логика.

Искусственные нейронные сети (*Artificial Neural Network, ANN*) – модели, имитирующие работу биологических нейронных сетей в человеческом мозге. Модели состоят из большого количества соединенных и взаимодействующих между собой искусственных нейронов, которые обрабатывают информацию и выполняют различные вычисления. Имеются большое число базовых структур моделей, включая глубокие сети, рекуррентные сети, сверточные сети и другие. Искусственные нейронные сети используются для решения широкого спектра задач, таких как распознавание образов, классификация данных, прогнозирование временных рядов, управление процессами и т. д.

В работе [76] поставлена задача спрогнозировать суточный график нагрузки города Петропавловска. Авторы предлагают использовать метод искусственных нейронных сетей в программе *MATLAB*. Погрешность прогнозирования суточных графиков нагрузки не превысила 2%. Исторические данные о электропотреблении и температуре воздуха были взяты в качестве исходных данных. В задаче также учитываются календарные признаки, в том числе тип дня.

В работе [54] проведено исследование нейронных сетей и ансамблевых моделей машинного обучения в задаче прогнозирования суточного графика электропотребления горнодобывающих предприятий. Показано, что предложенные методы являются более эффективными при учете динамики изменения нагрузки и нерегулярных составляющих.

Основное преимущество машинного обучения заключается в том, что устройство, обладающее этим свойством, способно обучаться на основе опыта и адаптироваться к изменяющимся условиям, что делает его очень

мощным инструментом для анализа и обработки данных. Машинное обучение также позволяет автоматизировать процессы анализа данных и выявления закономерностей, что может значительно повысить производительность и эффективность работы в различных областях энергетики.

1.3.3 Ансамблевые методы машинного обучения

Ансамблевые методы машинного обучения являются множеством регрессоров для получения более точных и достоверных моделей временных рядов. Основными типами являются такие алгоритмы, как случайный лес (*Random Forest, RF*), экстремальный градиентный бустинг (*Extreme Gradient Boosting, XGB*) и адаптивный бустинг (*Adaptive Boosting, Ada*). Эти методы основаны на принципе деревьев решений (*Decision Tree, DS*).

Дерево решения (Decision Tree, DS) [77] – это мощный инструмент для анализа больших данных, который может быть применен как для задач классификации, так и для регрессии. Дерево решения имеет иерархическую структуру без циклов и выглядит как древовидный комплект узлов и ветвей. Контроль по одному признаку осуществляется на узлах и результат каждого узла передается к следующим узлам по ветвям. Итоговые результаты регрессии и классификации формируются в конечных узлах, называемых листовыми. Рассмотрим временной ряд, который выражается следующим уравнением.

$$S_n = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}; \quad (1.10)$$

где x – исходные векторы, содержащие функции $f(x)$; y – выходные скаляры или метки; S_n – исследуемые выборки временного ряда (x_n, y_n) с номером наблюдения n .

Все первичные данные следует разделить на обучающие и тестовые наборы. Алгоритм обучается на обучающем наборе данных и создает модель, которая вычисляет зависимости между соответствующими признаками.

Иначе говоря, в конце процесса обучения выводится следующая функция модели временного ряда.

$$\hat{h}(x, S_n) = \frac{1}{m} \sum_{i=1}^m f_i(x_1, \dots, x_n) ; \quad (1.11)$$

где x_n – признаки, расположенные в узлах случайным образом; $m = 1, \dots, M$ – количество листьев дерева или число конечных узлов.

Для повышения эффективности этого алгоритма разработаны ансамблевые модели, объединяющие несколько деревьев решений. Общая структура ансамблевых моделей показана на рисунке 1.1.

Метод случайного леса (Random forest, RF) [78] – один из мощных ансамблевых алгоритмов, который использует множество деревьев решений для улучшения точности моделей. Из исходного обучающего набора данных S_n формируются несколько подвыборок размером n и размещаются в узлах деревьев решений [77, 79].




Рисунок 1.1 - Общая структура ансамблевых алгоритмов [80]

На каждом дереве проводится анализ регрессии или классификации подвыборок и выводятся их модели, которыми выражаются зависимости между случайными признаками. В конце анализа каждый регрессор дает выходную функцию $\hat{h}(x, S_n)$ и их результаты объединяются путем усреднения. В конечном итоге дает модель случайного леса:

$$\hat{Y}' = \frac{1}{q} \sum_{i=1}^q \hat{h}(x, S_n^i) ; \quad (1.12)$$

где S_n^i – i -ая случайная выборка; q – число деревьев решений.

Имеется способ повысить эффективность модели бегинга (*Bagging*) как случайного леса, который основан на принципе бустинга (*Boost*). Отличие этого принципа построения модели в том, что каждая последующая модель (регрессор) пытается исправить ошибки предыдущей.

Метод адаптивного бустинга (*Adaptive boosting, AdaBoost*) комбинирует несколько слабых элементов (*stumps*) для создания сильного набора регрессоров [81]. Чаще всего в качестве слабых элементов используются простые модели, например, деревья решений с небольшой глубиной (*max_depth*). В процессе обучения (или итерации) каждому дереву (элементу) присваивается вес, указывающий на его значимость. На первой итерации все образцы имеют одинаковый вес, а затем веса корректируются таким образом, чтобы образцы, которые были неправильно классифицированы, имели больший вес, а образцы, которые были правильно классифицированы, имели меньший вес. Итерация продолжается до тех пор, пока не будут минимизированы все веса. Предположим, что имеется следующий набор образцов.

$$S = \{(x_i, y_i) | i = 1, 2, \dots, N\}. D_{q(i)}; \quad (1.13)$$

где x_i – исходные переменные, y_i – выходные переменные, i – номер элемента выборки, $q = 1, 2, \dots, Q$ – номер итерации, D – весовые коэффициенты.

Обучение алгоритма осуществляется в описанной ниже процедуре:

1. Все регрессоры имеют одинаковый вес, который определяется следующим уравнением:

$$D_{1(i)} = 1/N; \quad (1.14)$$

где N – количество элементов выборки S_n набора.

2. Модель каждого регрессора $\hat{h}_q(x_i)$ строится с учетом весовых

коэффициентов, а далее вычисляется ошибка модели:

$$e_{q(i)} = |\widehat{h}_q(x_i) - y_i|, \quad e_{q(i)} \in [0,1]; \quad (1.15)$$

где $e_{q(i)}$ – ошибка i -ого элемента выборки на q -ой итерации, y_i – фактическое значение целевой переменной i -го элемента выборки.

3. Вычисляется относительная погрешность ε_q , которая определяется следующим уравнением:

$$\varepsilon_q = \sum_{i=1}^N D_{q(i)} e_{q(i)} ; \quad (1.16)$$

где $e_{q(i)}$ – погрешность, $D_{q(i)}$ – распределение весов i -ого элемента выборки на q -ой итерации.

4. В зависимости от ошибки весовой коэффициент пересчитывается следующим образом:

$$w_q = 1/2 \log(1/\beta_q); \quad (1.17)$$

при

$$\beta_q = \frac{\varepsilon_q}{1-\varepsilon_q}; \quad (1.18)$$

где w_q – весовой коэффициент.

5. Затем необходимо обновить распределение весов, установленное на предыдущих итерациях:

$$D_{q+1,(i)} = (D_{q,(i)} * \beta_q^{-\varepsilon_q}) / V_{q+1} ; \quad (1.19)$$

при

$$V_{q+1} = \sum_{i=1}^N D_{q+1,(i)} ; \quad (1.20)$$

где $D_{q+1,(i)}$ – новое распределение весов i -ого элемента выборки на $(q + 1)$ -ой итерации.

После завершения итерационного процесса алгоритм выдает окончательную модель, которая выражается следующим уравнением:

$$\hat{Y}' = \frac{1}{q} \sum_{q=1}^Q w_q \hat{h}_q(x) \quad ; \quad (1.21)$$

где $\hat{Y}'$ – выходная функция алгоритма, w_q – весовой коэффициент, $q = 1, 2, \dots, Q$ – номер итерации.

Адаптивный бустинг отличается от предыдущего алгоритма тем, что использует последовательный подход, где каждый новый слабый регрессор обучается на ошибках предыдущих. Другими словами, основная цель — исправить погрешности, сделанные предыдущими моделями. В результате, в принятии итогового решения участвуют не все элементы.

Экстремальный градиентный бустинг (Extreme gradient boost, XGB) [82] – ансамблевая модель, основанная на принципе градиентного спуска. Этот алгоритм отличается от предыдущих алгоритмов несколькими особенностями, в частности, он учитывает численную разницу между модельными значениями и реальными. Основная цель экстремального градиентного бустинга – минимизации ошибки методом градиентного спуска. Экстремальный бустинг можно рассматривать как модель, включающую в себя Q элементов (или регрессоров). Допустим, имеется следующий набор выборок:

$$S = \{(x_i, y_i) | i = 1, 2, \dots, N\}; \quad (1.22)$$

где x_i – исходные переменные, y_i – выходные переменные, i – номер элемента выборки.

Как правило, цель алгоритма экстремального градиентного бустинга стоит в минимизации погрешности. Таким образом, необходимо сформулировать целевую функцию:

$$L(y_i, \gamma) = \frac{1}{2} (y_i - \gamma)^2, \quad i = (1, 2, \dots, n); \quad (1.23)$$

где $L(y_i, \gamma)$ – функция потерь, определяющая отклонение прогнозируемых γ от фактических y_i значений, i – номер элемента выборки.

Реализация алгоритма осуществляется в описанной ниже процедуре:

Итерация начинается со значения $\hat{h}_0(x)$, которое равно среднему значению всех реальных значений y_i .

$$\hat{h}_0(x) = \arg \min_{\gamma} \sum_{i=1}^N L(y_i, \gamma) \quad ; \quad (1.24)$$

где $\hat{h}_0(x)$ – начальное прогнозируемое значение.

1. Остатки вычисляются следующим образом:

$$r_{iq} = - \left[\frac{\partial L(y_i, \hat{h}(x_i))}{\partial \hat{h}(x_i)} \right]_{\hat{h}(x) = \hat{h}_{q-1}(x)} \quad ; \quad q = (1, 2, \dots, Q); \quad (1.25)$$

где q – номер дерева, r_{iq} – остаток i -ого элемента выборки на q -м дереве, y_i – фактическое значение i -ого элемента выборки, $\hat{h}(x_i)$ – прогнозируемое значение i -ого элемента выборки.

2. На основе остатков r_{iq} повторяется процесс обучения алгоритма.
3. Далее определяется значения в конечных узлах деревьев решений:

$$\gamma_{jq} = \arg \min_{\gamma} \sum_{x_i \in R_{ij}} L(y_i, \hat{h}_{q-1}(x_i) + \gamma), \quad j = (1, 2, \dots, J); \quad (1.26)$$

где j – номер конечного узла, γ_{jq} – значение j -го узла на q -м дереве.

4. Значения модели обновляются с учетом результатов предыдущего шага γ_{jq} .

$$\hat{h}_q(x) = \hat{h}_{q-1}(x) + \mu \sum_{j=1}^{J_q} \gamma_{jq} I(x \in R_{jq}) \quad ; \quad \mu \in [0, 1]; \quad (1.27)$$

где $\hat{h}_q(x)$ – прогнозируемое значение q -го дерева, $\hat{h}_{q-1}(x)$ – прогнозируемое значение $(q - 1)$ -го дерева, μ – коэффициент уровня обучения.

Каждое добавление элемента (или регрессора) создает новую функцию, которую алгоритм изучает и определяет ее коэффициенты участия с целью минимизации ошибки предыдущих функций. В конце обучения алгоритм экстремального бустинга объединяет результаты всех итераций $\hat{h}_q(x)$ путем построения выходной модели $\hat{Y}'$.

$$\hat{Y}' = \frac{1}{q} \sum_{q=1}^q L(y, \hat{h}_{q-1}(x)) + \hat{h}_q(x) ; \quad (1.28)$$

где $\hat{Y}'$ – выходная функция алгоритма.

Ансамблевые модели, базирующиеся на одиночных регрессорах, позволяют обрабатывать большой объем данных и не требуют проведения сложной оптимизации настроек. Однако, такие гиперпараметры регрессоров, как глубина (*max_depth*) и количество (*n_estimators*) деревьев решений, сильно влияют на эффективность, точность и достоверность ансамблевых моделей. Поиск оптимальных гиперпараметров также необходим для построения моделей, так как пропорционально влияют на объем и время работы алгоритмов.

1.3.4 Метрики погрешности прогнозирования

Когда речь идет о прогнозировании, важно иметь метрики, позволяющие оценить точность модели. Прогнозирование представляет собой использование модели для неизвестных состояний процессов в будущем. Если модель адекватно отражает будущее, то ошибки в прогнозе будут примерно равны ошибкам самой модели. В ином случае ошибки могут увеличиться. Для оценки точности прогнозирования можно использовать метод инверсной верификации. При этом часть данных, полученных в прошлом, исключается из процесса подбора модели. Затем, создавая прогноз на основе модели и сравнивая его с реальными данными за определенный период, можно определить уровень ошибки. Некоторые из наиболее распространенных метрик погрешности прогнозирования включает в себя следующие характеристики.

1) Среднее по модулю ошибки (*Mean Absolute Error, MAE*) – это среднее значение абсолютных различий между фактическими и прогнозируемыми значениями. Чем ниже значение *MAE*, тем лучше модель.

$$MAE = \frac{1}{N} \sum_{m=1}^N |Y_m - \hat{Y}_m| \quad ; \quad (1.29)$$

где N – число элементов в выборке; $\hat{Y}_m$ – значение прогноза m -го элемента в выборке; Y_m – фактическое значение m -ого элемента в выборке.

2) Среднее по модулю ошибки в процентах (*Mean Absolute Percentage Error, MAPE*).

$$MAPE = \frac{1}{N} \sum_{m=1}^N \left| \frac{Y_m - \hat{Y}_m}{Y_m} \right| \cdot 100 \quad ; \quad (1.30)$$

где N – число элементов в выборке; $\hat{Y}_m$ – значение прогноза m -го элемента в выборке; Y_m – фактическое значение m -го элемента в выборке.

3) Средняя квадратичная ошибка (*Mean Squared Error, MSE*) – это среднее значение квадратов различий между фактическими и прогнозируемыми значениями. Она уделяет внимание большим различиям между значениями, чем MAE .

$$MSE = \frac{1}{N} \sum_{m=1}^N (Y_m - \hat{Y}_m)^2 \quad ; \quad (1.31)$$

где N – число элементов в выборке; $\hat{Y}_m$ – значение прогноза m -го элемента в выборке; Y_m – фактическое значение m -го элемента в выборке.

4) Коэффициент детерминации (*R-squared, R^2*) – это мера, которая показывает, насколько хорошо модель соответствует данным. Он может принимать значения от 0 до 1, где 1 означает идеальное соответствие.

$$R^2 = 1 - \sum_{m=1}^N (Y_m - \hat{Y}_m)^2 / \sum_{m=1}^N (Y_m - \bar{Y}_m)^2 \quad ; \quad (1.32)$$

где N – число элементов в выборке; $\hat{Y}_m$ – значение прогноза m -го элемента в выборке; Y_m – фактическое значение m -го элемента в выборке; $\bar{Y}_m$ – среднее значение в выборке m .

В диссертационной работе погрешность моделей оценивается методами: средней по модулю ошибки (*Mean Absolute Error, MAE*), средней по модулю ошибки в процентах (*Mean Absolute Percentage Error, MAPE*) и коэффициента детерминации (*R-squared, R^2*).

Если погрешности выше допустимых для практических расчетов, то модель недостоверна. Модель временного ряда должна систематически уточняться по мере накопления новых данных.

1.4 Методы оптимизации режимов электроэнергетических систем

Оптимизация режимов работы энергосистемы – одна из основных задач, решаемых при управлении режимами. Распределение активной мощности между источниками, планирование режимов работы ЭЭС и составление схемы электрической сети и другие задачи решаются путём оптимизации, которая обеспечивает получение наилучшего (оптимального) решения. В настоящем разделе описываются методы оптимизации, их классификация и формирование критериев.

Энергетическая система не только характеризуется высокой стабильностью и надежностью, но и демонстрирует большую эффективность, которую можно оценить по таким параметрам, как финансовые расходы, расход топлива, потери в сетях и т.д. Также важно учитывать влияние на окружающую среду, связанное с производством и использованием электроэнергии. Без оптимизации режимов управление энергосистемой не может полностью обеспечить максимальную экономическую эффективность и необходимую надежность. Таким образом, одной из ключевых задач является нахождение оптимального решения для повышения эффективности, стабильности и надежности работы энергосистемы.

Первые применения методов оптимизации относятся еще ко времени зарождения первых цивилизаций. Распределение ресурсов, планирование работ, организация маршрутов и многие другие проблемы были актуальными на протяжении всей истории человечества, но математические модели для их формального описания и методы применения разработаны относительно недавно. Термин «оптимум» был введен в XVIII веке Г.В. Лейбницем и в основном рассматривался в применении к теологии – учению о религиозных

догматах и религиозной культуре и их необходимости для человека. В переводе с латинского термин *optimus* означает наилучший. Исторически выявлено несколько математических закономерностей, лежащих в основе теории оптимизации. Например, в XVII веке Пьер Ферма установил закономерность, заключающуюся в том, что при приближении к точкам максимума и минимума скорость изменения функции падает до нуля. Основными трудами являются работы Даниила Бернулли, Леонарда Эйлера, Жозефа Л. Лагранжа, посвященные вариационному исчислению [84].

В настоящее время наиболее значительный вклад в решение данной проблемы внесли такие ученые, как Д.А. Арзамасцев, А.В. Пантелеев, Т.А. Летова, Ю.М. Сидоркин, Ю.А. Секретарев, П.В. Матренин, А.М. Брамм, А.И. Хальясмаа, С.А. Ерошенко, В.М. Горнштейн, Т.В. Мятеж, Б.П. Мирошниченко, Е.В. Цветков и другие зарубежные. Следует также отметить, что на протяжении многих лет развитию новых методик и способов решения оптимизационных задач было уделено значительное внимание.

Оптимизация процессов в электроэнергетике рассматривает однокритериальные и многокритериальные задачи в соответствии с количеством и типом критериев. Данные задачи решаются различными методами, которые классифицируются как детерминированные и стохастические. В работах [13-22] описаны методов оптимизации и значительное внимание было уделено их применению и разработке.

Детерминированные методы – это подходы, предполагающие, что все параметры и условия задачи известны и фиксированы, т.е. процессы в системе отражены с позиции полной определенности как в настоящем, так и в будущем. Поиск оптимального решения осуществляется с использованием математических моделей и алгоритмов, которые не зависят от случайных факторов и способны перечислить все возможные решения и выбрать оптимальный. Таким образом, используются строгие математические методы, такие как линейное [85-87] и нелинейное программирование, включая градиентный спуск [88], методы множителей Лагранжа [89, 90] и Ньютона, а

также динамическое программирование [91, 92]. Среди перечисленных методов самыми распространенными считаются методы нелинейного программирования, в том числе методы градиентного спуска и метод множителей Лагранжа. В системах, имеющих огромное количество возможных вариантов, детерминированные методы неприемлемы.

Неопределенность информации может быть связана с природными явлениями или процессами. Большинство процессов в энергетике характеризуется такой неопределенностью из-за сложной структуры и больших размеров энергосистемы. В тех случаях, когда с каждой принимаемой стратегией связано множество возможных результатов, говорят о принятии решений в условиях неопределенности и риска. Стохастические методы [16, 17, 19, 93], включая генетические алгоритмы [94-96], метод случайного поиска [97], алгоритм имитации отжига [98, 99] и другие, могут быть применены для решения задач оптимизации таких хаотических и сложных систем.

В настоящее время недостатки детерминированных методов приводят к необходимости разработки новых нетрадиционных методов, а именно стохастических, основанных на искусственном интеллекте. Несмотря на это, стоит отметить, что каждый алгоритм стохастических методов может иметь ряд преимуществ и недостатков. Для повышения эффективности моделей стохастических методов необходимо разрабатывать новые способы и модификации, что вызывает усложнение их реализации. Стоит отметить, что не существует одного оптимального алгоритма для конкретной цели, и они всегда не дают наилучшего решения.

1.4.1 Общий принцип математической формулировки

Задачи оптимизации решаются с использованием математических моделей и программирования. В общем случае рассматривается формальное описание задачи, критерий решения задачи, независимые и зависимые

переменные, уравнения связи между переменными, ограничения на переменные в форме равенств и неравенств.

Вид функции, описывающей цель, позволяет говорить о задачах линейных и нелинейных, тип переменных – о дискретных и непрерывных задачах, распределенность процессов во времени – о статических и динамических задачах.

Для построения оптимизационной модели необходимо выбрать независимые и зависимые переменные, которые описывают особенности рассматриваемой системы. Например, в задаче оптимизации режимов работы ТЭЦ расход топлива является независимой переменной, а выработка электрической или тепловой энергии – зависимыми переменными. Связь этих переменных отражается на работе ТЭЦ, для которой проводится оптимизация.

В режимных задачах применяются критерии оптимизации, такие как технические и экономические. В зависимости от того, где и с какой целью решается оптимизационная задача, следует использовать соответствующий критерий. Например, для тепловой электростанции часто используются технические критерии, такие как минимум расхода топлива, максимум КПД и др. При оптимизации режимов работы энергосистем рассматривается несколько критериев в более широком контексте. На практике, критерий оптимизации называется целевой функцией, имеющей следующий вид:

$$F(X, Y) \rightarrow \text{extr}; \quad (1.33)$$

Задача оптимизации сводится к отысканию экстремума с учетом уравнений связи между зависимыми и независимыми переменными, которые часто рассматриваются как ограничения в форме равенств. Уравнения связи определяют отношения между переменными и описываются следующим образом.

$$W(X, Y) = 0; \quad (1.34)$$

Уравнением ограничений определяются допустимые пределы, в которых изменяются значения независимых и зависимых переменных и

функций от них. Оптимальное решение должно лежать в заданных пределах режимных условиях, записанных в виде следующих неравенств:

$$X_{\min} \leq X \leq X_{\max}; \quad (1.35)$$

$$Y_{\min} \leq Y \leq Y_{\max}; \quad (1.36)$$

$$h_{\min} \leq h'(X, Y) \leq h_{\max}; \quad (1.37)$$

Если целевая функция и ограничения линейны, то задачу оптимизации можно решать методами линейного программирования. Если хотя бы одна из функций нелинейна, то эта задача является нелинейной.

1.4.2 Детерминированные методы оптимизации

Линейное программирование используется для оптимизации линейных функций при линейных ограничениях [22]. В энергетике большинство процессов описываются функцией, состоящей из одной или нескольких линейных зависимостей. Таким образом, может быть применен метод линейного программирования в энергетических задачах. В случае применения метода линейного программирования целевая функция представляет собой стандартную матричную форму.

$$F(X) = aX + b \rightarrow \text{extr}; \quad (1.38)$$

при ограничениях

$$\left| \begin{array}{l} X \leq B_1 \\ X = B_2 \\ B_3 \leq X \leq B_4 \end{array} \right|; \quad (1.39)$$

где $F(X)$ – целевая функция, X – зависимая переменная, B_1, B_2, B_3, B_4 – значения ограничений.

Часто используемым алгоритмом для решения задач линейного программирования является симплекс-метод, использующий для оптимизации целевую функцию при линейных ограничениях. Принцип алгоритма заключается в достижении оптимального решения за счет поиска и перебора от одной вершины многогранника ограничений к другой. Математическая

формулировка целевой функции имеет следующий вид.

$$F(X) = b + \sum_{i=1}^N a_i X_i \rightarrow \text{extr} ; \quad (1.40)$$

где b – свободный член, a_i – коэффициенты.

Симплекс-алгоритм имеет следующие особенности в отличие от других линейных и нелинейных методов. Во-первых, он может решать задачи с большим количеством переменных и ограничений, часто за относительно короткое время. Современные реализации этого метода могут обрабатывать большие объемы данных и сложные модели. С другой стороны, задача оптимизации должна быть правильно сформулирована в виде линейной модели, что не всегда просто.

Метод множителей Лагранжа является алгоритмом, используемым для нахождения экстремумов функций при наличии ограничений. Метод основан на принципе поиска экстремума функции Лагранжа, который включает в себя добавление к целевой функции суммы произведений множителей Лагранжа. Рассмотрим принцип метода множителей Лагранжа.

Предположим поставлена задача найти условный экстремум нелинейной функции $F(X_1, X_2, \dots, X_n)$ с n переменными при m ограничениях.

$$F(X_1, X_2, \dots, X_n) \rightarrow \text{extr}; \quad (1.41)$$

Условия ограничений можно выразить следующим образом:

$$H_1(X_1, X_2, \dots, X_n) \geq B_1 ; \quad (1.42)$$

$$H_2(X_1, X_2, \dots, X_n) \leq B_2 ; \quad (1.44)$$

.....

$$H_m(X_1, X_2, \dots, X_n) = B_m . \quad (1.45)$$

Все ограничения необходимо преобразовать в равенства, а свободные члены B_m перенести в левые части выражения. Система ограничения принимает следующий вид.

$$H_1(X_1, X_2, \dots, X_n, B_1) = 0 ; \quad (1.46)$$

$$H_2(X_1, X_2, \dots, X_n, B_2) = 0 ; \quad (1.47)$$

.....

$$H_m(X_1, X_2, \dots, X_N, B_m) = 0. \quad (1.48)$$

Как правило, вместо относительного экстремума функции $F(X_1, X_2, \dots, X_N)$ при переформулированных ограничениях ищется абсолютный экстремум функции Лагранжа, которую можно записать следующим образом.

$$L = F(X_1, X_2, \dots, X_N) + \lambda_1 H_1(X_1, X_2, \dots, X_N, B_1) + \lambda_2 H_2(X_1, X_2, \dots, X_N, B_2) + \dots + \lambda_m H_m(X_1, X_2, \dots, X_N, B_m) \rightarrow \text{extr}; \quad (1.49)$$

Очевидно, что функция Лагранжа L строится путем суммирования целевой функции $F(X)$ и ее переформированных ограничений $H_i(X)$, умноженных на множитель Лагранжа λ_i . Таким образом можно кратко записывать математическую модель данного метода.

$$L(X, \lambda) = F(X) + \sum_{i=1}^m \lambda_i H_i(X) ; \quad (1.50)$$

где λ_m – неопределенные множители Лагранжа m -го ограничения, $F(X)$ – целевая функция, $H_i(X)$ – ограничения.

Этот метод позволяет свести задачу условной оптимизации к безусловной оптимизации путем поиска стационарных точек функции Лагранжа. При правильном выборе множителей Лагранжа и их последующем использовании можно найти точку экстремума и определить оптимальное значение целевой функции при заданных условиях. Недостатком метода является увеличение объема расчётов за счет введения множителей Лагранжа, что может привести к невозможности принятия решения. Для устранения этого недостатка, используя градиентные методы или метод Ньютона, можно упростить функции $L(X, \lambda)$.

Градиентные методы – это класс методов оптимизации, использующих информацию о градиенте целевой функции для поиска её экстремума. Градиент целевой функции указывает направление наивысшего изменения функции, поэтому градиентные методы

позволяют находить минимум или максимум функции, двигаясь в направлении, противоположном градиенту. Рассмотрим математические формулировки:

$$\Delta X^i = -grad F(X^i) = -\nabla F(X^i); \quad (1.51)$$

Вектор градиента рассчитывается через производные $F(X)$ по всем n независимым переменным.

$$\nabla F = \begin{bmatrix} \frac{dF}{dX_1} \\ \dots \\ \frac{dF}{dX_n} \end{bmatrix}; \quad (1.52)$$

Таким образом, математическая модель методов градиентного спуска можно записать в следующем виде:

$$X^{i+1} = X^i - a \cdot \nabla F(X^i); \quad (1.53)$$

где a – коэффициент скорости при градиенте функции $F(X)$, X^{i+1} – вектор неизвестных на $(i + 1)$ -й итерации.

Градиентные методы широко используются в машинном обучении, оптимизации нейронных сетей, а также в других областях, где требуется решение задач оптимизации. Их преимущества включают высокую эффективность и простоту реализации, но при этом они могут сталкиваться с проблемами, такими как выбор оптимального уровня обучения (*learning rate*) и преодоление локальных минимумов. Кроме того, главным недостатком является невозможность нахождения глобального экстремума, так как при достижении локального экстремума градиент становится равным нулю, эти методы неспособны осуществлять поиск других экстремумов. Внесение некоторых модификаций позволяет избежать этих недостатков.

Метод Ньютона является одним из методов второго порядка и имеет лучшую сходимость по сравнению с другими детерминированными методами. Метод основан на использовании производной функции для приближенного определения корня. За счет использования квадратичной аппроксимации метод Ньютона сокращает количество итераций. Каждая

новая точка определяется с помощью рекуррентного выражения. В общем виде математическая модель записывается следующим рекуррентным выражением:

$$X^{i+1} = X^i - [F''(X^i)]^{-1} \cdot F'(X^i) \quad (1.54)$$

или

$$\Delta X^i = X^{i+1} - X^i = - \left[\frac{d^2 F(X^i)}{dX^2} \right]^{-1} \frac{dF(X^i)}{dX} \quad (1.55)$$

где i – номер итерации; $F''(X^i)$ – матрица вторых частных производных, взятых в точке X^i , называется матрицей Гессе и обозначается H . Матрица Гессе – положительно определенная симметричная матрица; $F'(X^i)$ – вектор первых частных производных, т. е. градиент ∇F .

Метод Ньютона обычно сходится быстро к корню уравнения, особенно если начальное приближение выбрано близко к корню. Однако он может быть неэффективен, если производная функции близка к нулю в окрестности корня.

1.4.3 Стохастические методы оптимизации

Генетические алгоритмы используют эвристические методы оптимизации, подобные естественному отбору и механизмам генетики, в которых сохраняется в упрощенном виде биологическая терминология [93, 96]. Иначе говоря, принцип генетических алгоритмов основан на концепциях естественного отбора, таких как селекция, скрещивание и мутация. Этот алгоритм применяется в сложных задачах оптимизации, особенно стохастических проблемах.

Возможное решение обычно представляется в виде бинарных значений или вектора, а также можно использовать и другие представления. Их называют хромосомами или особями, а множество решений – популяцией. Поиск хромосом с наилучшим решением (оптимальным решением)

выполняет следующие операции:

1. инициализация начальной популяции, состоящей из индивидуумов (потенциальных решений);
2. оценка каждой популяции с помощью функции приспособленности, которая определяет, насколько хорошо они решают поставленную задачу;
3. выбор лучших популяций для размножения и создания новой популяции;
4. размножение выбранных популяций с использованием генетических операторов, таких как скрещивание и мутация, для создания потомства;
5. оценка приспособленности новой популяции;
6. повторение операции 3-5 до достижения критерия останова, например, определенного количества поколений (итераций) или достижения определенного уровня приспособленности.

Генетический алгоритм является комбинированным методом, созданный из двух групп методов оптимизации: перебора и итерации. Операции скрещивания и мутации относятся к переборной части, а отбор лучших решений – к градиентному спуску. Преимущество алгоритма в том, что он эффективен при поиске оптимального решения в большом пространстве. Причем генетический алгоритм – более эффективный по сравнению с детерминированными методами. Однако он может потребовать большого объема вычислений и времени реализации, а также может быть сложен для задания параметров настройки [19].

Алгоритм роя частиц относится к метаэвристическим алгоритмам оптимизации, созданным на основе поведения стад или роев в природе. В настоящее время получили известность некоторые алгоритмы роевого интеллекта в задаче стохастической оптимизации. Алгоритмы роевого интеллекта описаны во многих литературах, но единого объяснения не существует [100].

Как правило, агентами считаются точки (решения), находящиеся в

пространстве поиска решений, имеющие одинаковые особенности и конкретную цель. Основным принципом алгоритма является перемещением агентов в заданном пространстве. Создание новых популяций агентов выполняется за счет информации о движении агентов, полученной на предыдущих итерациях, т. е. из предыдущих популяций. Отличие от генетических алгоритмов состоит в отсутствии процесса отбора, скрещивания и мутации агентов. Если под агентом понимается частица, то речь идет об алгоритме роя частиц, суть которого заключается в движении частиц в пространстве решений. Каждая частица оценивает свое текущее местоположение в пространстве и ищет еще лучшее. Они помнят самое лучшее место, где они были, и всегда стремятся туда вернуться. В результате стремления к наилучшему положению всех частиц достигается глобальный экстремум в пространстве. Алгоритм роя частиц состоит из следующих этапов:

1. инициализация начальной популяции агентов, каждый из которых представляет потенциальное решение задачи оптимизации;
2. определение функции приспособленности для каждого агента, оценивающее ее качество как решения задачи;
3. обновление локального экстремума для каждого агента на основе его собственной истории и истории соседних агентов;
4. обновление глобального экстремума на основе локального экстремума всех агентов;
5. движение каждого агента в пространстве поиска оптимального решения на основе его текущего положения;
6. повторение операции 3-5 до достижения критерия останова, такого как определенное количество перемещения частиц (итераций) или достижение определенного уровня приспособленности.

Алгоритм роя частиц – эффективный алгоритм в поиске оптимального решения в многомерных пространствах и имеет ряд преимуществ: требование небольшого числа параметров и формул, простота реализация, и

малая зависимость от исходных параметров. Алгоритм также имеет возможность поиска локальных экстремумов, но при этом требует настройки параметров. Недостатками являются низкий уровень сходимости, частое попадание в точки локального экстремума, и зависимость сходимости от значений параметров алгоритма.

1.5 Описание энергосистемы Монголии

Электроэнергетика Монголии состоит из пяти независимых энергосистем: Центральной, Восточной, Западной, Алтай-Улиастайской и Южно-Гобийской, как показано на рисунке 1.2. На основе статистических данных [101, 102] ниже представлена краткая информация о перечисленных энергосистемах.

В Восточной энергосистеме вырабатывает энергию только одна ТЭЦ установленной мощностью 36 МВт, поддерживая частоту и напряжение. В 2022 г. Чойбалсанская ТЭЦ выработала 242,7 млн кВт.ч и максимальная нагрузка составляла 35,8 МВт.

Южная энергосистема обеспечивает электроэнергией крупный горно-обогатительный комбинат Оюу-Толгой только за счет импорта из Китая.



Рисунок 1.2 - Энергосистемы Монголии

Алтай-Улиастайская энергосистема своеобразна тем, что в ее составе шесть малых ГЭС, одна солнечная электростанция мощностью 10 МВт и две дизельные станции малой мощности. Из них Тайширская ГЭС – самая большая ГЭС установленной мощностью 11 МВт, а остальные имеют суммарную установленную мощность до 2 МВт. Основное регулирование электроэнергетического режима реализуется за счет параллельной работы с Центральной энергосистемой (ЦЭС) по воздушной линии напряжением 110 кВ. В 2022 г. электропотребление достигло 108,4 млн кВт.ч, увеличившись на 9,2 % по сравнению с 2021 г.

Электропотребление Западной энергосистемы в 2022 году составило 238,2 млн кВт.ч, из них 12,1 % было произведено на ГЭС «Дургун» (установленная мощность 12 МВт) и 6,5% - на солнечной электростанции «Ховд». Оставшуюся часть в 81,4% покрывала импортная электроэнергия из России и Китая. Максимальная нагрузка западной энергосистемы достигала до 48 МВт.

Центральная энергосистема (ЦЭС) занимает значительное место в энергетике Монголии, которая охватывает районы с высокой плотностью населения, такие как Улан-Батор, Эрдэнэт и Дархан. ЦЭС также поддерживает развитие тяжелой и горнодобывающей промышленности, что делает её критически важной для экономического роста. В 2022 г. электростанции ЦЭС вырабатывали 7745,2 млн кВт.ч электроэнергии, а пиковая нагрузка достигла 1469 МВт 16 декабря. На территории ЦЭС расположены 7 ТЭЦ, 1 КЭС, 3 ВЭС и 6 СЭС с разной установленной мощностью.

В 2020 г. по заказу Министерства энергетики Монголии был разработан мастер-план до 2030 года, который является официальным документом государственной политики развития энергетики. С учетом промышленного развития, роста внутреннего валового продукта и других энергетических условий определен годовой рост электропотребления.

Согласно этому документу среднегодовые темпы роста электропотребления в 2019–2030 годах для низкого, базового и высокого варианта составляют 4,1, 7,4 и 9,6 % соответственно. График пикового потребления электроэнергии показан на рисунке 1.3.




Рисунок 1.3 - График прогноза пикового электропотребления [101]

ЦЭС выбрана объектом для внедрения результатов диссертационного исследования. В данной энергосистеме расположена значительная доля выработки и потребления электроэнергии в Монголии.

1.5.1 Установленная мощность Центральной энергосистемы

На данный момент установленная мощность ЦЭС Монголии составляет 1488 МВт, из которых 84 %, или 1243 МВт, генерируются ТЭЦ, а остальные 16 %, или 245 МВт, – ВИЭ, такими как солнечные и ветровые. В настоящее время, в ЦЭС отсутствуют быстроманевренные агрегаты для покрытия нерегулярной составляющей суточного графика нагрузки, в

частности ГЭС и ГАЭС. За счет импорта/экспорта электроэнергии с ЕЭС России через ЛЭП 220 кВ Селендума – Дархан обеспечивается баланс активной и реактивной мощности, регулирование напряжения и поддержание необходимых показателей качества электроэнергии.

По статистике [102], в 2022 г. общая генерация электроэнергии ЦЭС составила 7 829,4 млн кВт.ч, из них 92 % выработано ТЭЦ, а 8 % – ВИЭ. Импорт электроэнергии из России и Китая составил около 20 % от общего потребления электроэнергии ЦЭС. В соответствии с растущей потребностью правительство Монголии рассматривает следующие проекты строительства электростанций в ближайшем будущем [101, 102]:

- Тавантолгой КЭС мощностью 450 МВт;
- Багануурская ТЭЦ мощностью 400 МВт;
- Буурулжуут КЭС мощностью 300 МВт;
- Багахангайская КЭС мощностью 300 МВт;
- Шуренская ГЭС мощностью 300 МВт;
- Ерууская ГАЭС мощностью 100 МВт;
- Майханская ГАЭС мощностью 75 МВт;
- Хэрлэнская ГАЭС мощностью 45 МВт;
- Хуйтенская ГАЭС мощностью 30 МВт.
- Шивээ-Овоо КЭС мощностью 1400 МВт на экспорт в Китай.

Согласно государственной политике Монголии для сокращения выбросов парниковых газов, связанных с энергетикой, ставится цель увеличить объем мощностей возобновляемой энергии на 30 % к 2030 г. Так, модернизация структуры ЭЭС, в том числе растущая интеграция ВИЭ, оказывают существенное влияние на функционирование ЭЭС, требуют совершенствования методологии планирования режимов на сутки вперед. Таблица 1.1 детализирует информацию существующих источников электроэнергии данной энергосистемы.

Таблица 1.1 – Источники электроэнергии ЦЭС Монголии

	Наименование	Год ввода в строй	Возраст, год	Установленная мощность, [МВт]
1	ТЭЦ – 2	1961	62	24
2	ТЭЦ – 3	1968	54	198
3	ТЭЦ – 4	1983	40	772
4	ТЭЦ – Дархан	1965	58	83
5	ТЭЦ – Эрдэнэт	1987	36	86
6	ТЭЦ – ГОК	2018	5	53
7	ТЭЦ – Даланзадгад	2000	23	9
8	КЭС – Ухаахудаг	2011	12	18
9	ВЭС – Салхит	2013	10	50
10	ВЭС – Цэций	2017	6	50
11	ВЭС – Шанд	2018	5	55
12	СЭС – Дархан	2017	6	10
13	СЭС – Моннар	2017	6	10
14	СЭС – Бухуг	2019	4	15
15	СЭС – Сумбэр	2019	4	10
16	СЭС – Говь	2019	4	30
17	СЭС – Гэгээн	2018	5	15

1.5.2 Ресурсы возобновляемой энергии

Монголия обладает значительными запасами как традиционных источников энергии (бурый уголь), так и возобновляемых, включая солнечную, ветровую и гидроэнергию. В настоящее время бурый уголь играет важную роль в электро- и теплоэнергетике страны благодаря своим огромным резервам, оцениваемым в 173 миллиарда тонн. Богатые возобновляемые ресурсы также открывают большие возможности для развития энергетического сектора страны [103].

Ветровая энергия Наиболее авторитетной оценкой ветроэнергетического потенциала Монголии является атлас ветровых ресурсов, составленный Национальной организацией по возобновляемой энергетике (*National Renewable Energy Laboratory, NREL*). Согласно данному атласу, подветренная территория, где можно развивать ветроэнергетические установки, занимает около 10 % всей территории Монголии. На рисунке 1.4

показан потенциал ветровой энергии. Объем потенциальной мощности на этой территории оценивается более чем в 1,1 ТВт, что может обеспечить выработку 2,5 трлн кВт.ч электроэнергии в течение года [101, 104]. Этот объем эквивалентен примерно половине общего потребления электроэнергии в Китае в 2014 г.

Солнечная энергия. В Монголии в среднем 270...300 солнечных дней в году, а продолжительность естественного освещения, при котором возможна выработка электроэнергии, составляет примерно 2250...3300 часов в год. Монголия также имеет большой потенциал для солнечной энергетики благодаря высокому уровню солнечной радиации, особенно в пустынных и полупустынных регионах. При среднесуточном количестве солнечной энергии в диапазоне 3,4...5,4 кВт.ч/м² на общей площади 23 461 км² Монголия имеет потенциал для выработки 4774 ТВт.ч солнечной электроэнергии в год, как показано в таблице 1.2 и на рисунке 1.5 [101, 104].

Таблица 1.2 – Ресурс солнечной энергии

Радиация, [кВт.ч/м ² в сутки]	Площадь территории, [км ²]	Потенциал, [ТВт.ч в год]
3,4	5 269	654
3,8	3 924	544
4,1	4 210	630
4,5	4 515	742
5,4	5 542	1 092
Итого	23 461	4 774

По предварительным расчетам, центральная часть Монголии, особенно территория пустыни и полупустыни, занимает третье место в мире по потенциалу солнечной и ветровой энергии. В частности, регион Гоби, граничащий с северным Китаем, является территорией с огромными запасами возобновляемой энергии, включая солнечную и ветровую энергию. Данная территория является приоритетной для производства электроэнергии из возобновляемой энергии и развития инфраструктуры ЦЭС Монголии.




Рисунок 1.4 - Атлас распределения ветровой энергии на территории Монголии




Рисунок 1.5 - Потенциал солнечной энергии на территории Монголии

1.5.3 Вопросы управления Центральной энергосистемой

В Монголии ОАО «Национальный диспетчерский центр» (НДЦ) – единственная организация, осуществляющая непрерывный управление режимами ЭЭС и их контроль, а также являющаяся единым покупателем на оптовом и розничном рынках электроэнергии. Другими словами, роль этой организации заключается не только в системном, но и в коммерческом операторе. Поставщики электроэнергии (генерирующие компании) предлагают системному оператору такие информации, как общее производство электро- и теплоэнергии, предельную мощность, и количество включенных агрегатов. А сбытовые компании (сетевые компании) покупают электроэнергию на оптовом и розничном рынках по установленному тарифу и продают ее как потребителям, так и крупным промышленным предприятиям. Проще говоря, оптовый рынок электроэнергии ЦЭС Монголии функционирует по модели единого покупателя. С точки зрения коммерческого оператора, цель управления электроэнергетической системой заключается в снижении цены продажи электроэнергии. С другой стороны, оператор должен непрерывно осуществлять оперативно-диспетчерское управление, обеспечивая надежность и устойчивость энергосистемы в качестве системного оператора.

Управление режимами центральной энергосистемой осуществляется по трехуровневой иерархической структуре, включающей центры диспетчерского управления, обеспечивающие распределение и передачу электроэнергии, а также главный диспетчерский центр. За счет применения систем контроля и управления, таких как программный комплекс *SCADA Siemens Spectrum Power™* и система мониторинга переходных режимов *WAMS*, управление текущими режимами достигло достаточно высокого уровня.

Планирование режимов энергосистем осуществляется в следующих

временных интервалах.

- Годовое планирование основано на учете макроэкономических показателей и информации об ожидаемом электропотреблении от энергопринимающих компаний. Также рассматриваются предложения по производству электро- и теплоэнергии от традиционных источников.
- Месячное планирование, определяющее состав включенного генерирующего оборудования с учетом ожидаемого потребления электро- и теплоэнергии.
- Планирование на сутки вперед, при котором учитываются такие факторы: данные предыдущего дня, особенности календаря, данные о метеорологических факторах, заявки на отключение потребителей и изменения режимов работы на предприятиях крупной промышленности.

По данным отчета НДЦ, средняя ошибка прогнозирования суточного графика нагрузки составляет примерно от 2,0 до 3,0 %, а для генерации ВИЭ она сравнительно велика и варьируется от 26,0 до 41,0 %. На данный момент краткосрочное прогнозирование, в частности составление суточного графика выработки ВИЭ, основывается только на прогнозах метеорологов и интуиции. Безусловно, составление плана на сутки вперед с такими погрешностями прогнозирования усложняет управление текущими режимами работы ЭЭС.

В настоящее время суточное планирование режимов работы реализуется путём использования *Microsoft Excel*. Другими словами, при планировании режимов работы не используются методы оптимизации. Принцип планирования заключается в покрытии суточного графика нагрузки за счет внутренних источников энергии и импорта. Недостатком является то, что не позволяет достигнуть максимальной экономичности, поскольку не учитываются требования оптимальности. Причем не рассчитывается установившийся режим работы ЭЭС.

В настоящее время для ЦЭС Монголии весьма актуальна задача совершенствования методологии как прогнозирования, так и планирования

режимов работы в краткосрочной перспективе.

Выводы по главе 1

В главе 1 главное внимание было уделено теме краткосрочного планирования режимов электроэнергетических систем, являющегося одной из фундаментальных задач управления режимами. Описаны существующие методы прогнозирования и оптимизации, которые могут стать основой для разработки систем предиктивной аналитики. Имеется большое число публикаций в периодической печати, а также в материалах конференций и симпозиумов, посвящённых рассматриваемой задаче. Этими работами подтверждается актуальность темы краткосрочного планирования режимов работы ЭЭС, а также в достаточной степени описаны используемый методы. Установлено, что не существует единого универсального метода или подхода к решению поставленных задач, полностью удовлетворяющего всем требованиям и не имеющего недостатков. Каждый метод и подход имеет свои преимущества, недостатки и ограниченную применимость.

Особое внимание уделено описанию ЭЭС Монголии, а именно Центральной энергосистемы, в которой размещена основная часть потребления и генерации электроэнергии. Особенностью этой энергосистемы в том, что значительная часть электроэнергии вырабатывается возобновляемыми источниками энергии. Традиционным тепловым электростанциям отводится основная роль как в настоящем, так и в будущем. В связи с этим, в течение последних десятилетий возникают проблемы в управлении режимами. На данный момент, с помощью систем управления SCADA и WAMS управление текущими режимами реализуется на достаточно высоком уровне. Что касается планирования режимов на сутки вперед, то прогнозирование процессов осуществляется методом эвристического анализа на основе исторических данных, а математические методы оптимизации пока не используются.

Таким образом, разработка систем предиктивной аналитики режимов для Центральной энергосистемы Монголии – эта тема весьма актуальна и требует особого внимания. По итогам результатам рассмотрения материалов, представленных в этой главе, сделан вывод, что для эффективных решений поставленных задач необходимо использовать комбинацию различных методов как классических, так и интеллектуальных, подходящую к особенностям объекта исследования.

ГЛАВА 2 РАЗРАБОТКА МЕТОДИКИ ПРОГНОЗИРОВАНИЯ СУТОЧНОГО ГРАФИКА НАГРУЗКИ ДЛЯ ЦЕНТРАЛЬНОЙ ЭНЕРГОСИСТЕМЫ МОНГОЛИИ

Прогнозирование потребления электроэнергии является одной из основных теоретических и практических задач в энергетике на сегодняшний день. Своевременное получение информации о предстоящей нагрузке позволяет выбрать оптимальный режим электроэнергетической системы (ЭЭС), а точность его результатов значительно влияет на показатели всего электротехнического комплекса в условиях работы на рынке электроэнергии, чего можно достичь, используя модель общего потребления электроэнергии, выполненную с допустимой погрешностью. Это обуславливает актуальность задачи, рассматриваемой в данной главе.

Построение моделей и прогнозирование суточного графика нагрузки электропотребления рассматривается на реальной энергосистеме и его составляющих (на примере ЦЭС Монголии). В задаче прогнозирования суточного графика нагрузки ЭЭС применяются традиционные методы, включая линейную регрессию и авторегрессию, а также методы искусственного интеллекта, основанные на ансамблевых алгоритмах, таких как случайный лес (*Random Forest*), экстремальный градиентный бустинг (*XGBoost*) и адаптивный бустинг (*AdaBoost*). Для моделирования нагрузки в узлах также использовались ранговые коэффициенты.

В поставленной задаче данной главы исходными переменными были выбраны суточные графики нагрузки ЦЭС, занимающей значительную часть потребления и выработки электроэнергии в Монголии, а также, метеорологические и календарные данные, за период 2019-2021 гг. Программная реализация и эксперименты проводились на языке программирования *Python*.

2.1 Задача прогнозирования суточного графика нагрузки ЭЭС

2.1.1 Анализ влияния метеофакторов на электропотребление

Электропотребление является нестационарным процессом, динамика которого определяется такими составляющими, как тренд, сезонность, цикличность и случайность [33]. Известно, что существует ряд факторов, влияющих на режим потребления электроэнергии и, соответственно, на качество его прогнозирования. Эти факторы можно разделить на следующие группы: латентные (явные и неявные) факторы, внутрисистемные (эндогенные) и внесистемные (экзогенные) факторы [105]. К явным эндогенным факторам относятся такие факторы, как частота, напряжение и другие параметры, связанные с системой энергоснабжения. Что касается явных экзогенных факторов, то в них входят метеорологические и календарные особенности.

Особую роль среди вышеперечисленных факторов в задачах прогнозирования энергопотребления играют метеорологические факторы, в частности температура воздуха. На рисунке 2.1 представлены графики электропотребления и температуры воздуха за 2021 год для ЦЭС Монголии.




Рисунок 2.1 - График среднесуточного электропотребления и среднесуточной температуры наружного воздуха на территории ЦЭС Монголии за 2021 год

В исследованиях [105-111] достаточно доказывается, что электропотребление зависит от данных факторов. Этими факторами определяется сезонные колебания, а также нерегулярный компонент потребления электроэнергии. На графиках, представленных на рисунке 2.1, показаны сезонные циклы, на которых изображена зависимость электропотребления от температуры наружного воздуха. По представленному графику можно построить зависимость электропотребления от температуры наружного воздуха, характеризующую период с 1 января 2021 г. по 31 декабря 2021 г. на территории ЦЭС Монголии, как представлено на рисунке 2.2.




Рисунок 2.2 - Зависимость электропотребления от температуры наружного воздуха

Эта зависимость оценивается средствами регрессионного анализа и корреляционного анализа. Корреляционный анализ – это статистический метод, используемый для определения связи между двумя или более переменными, которая выражается коэффициентом Пирсона. Коэффициент Пирсона r_{xy} определяется по следующей формуле:

$$r_{xy} = \frac{\sum (x_i - x_{cp})(y_i - y_{cp})}{\sqrt{\sum (x_i - x_{cp})^2 \sum (y_i - y_{cp})^2}}; \quad (2.1)$$

где x_i – значения, принимаемые в выборке X ; y_i – значения, принимаемые в выборке Y ; x_{cp} – средняя по X ; y_{cp} – средняя по Y .

Коэффициент корреляции принимает значения от -1 до 1. Если значение коэффициента корреляции отрицательное, то связь между двумя переменными может быть следующей: когда значения одной переменной уменьшаются, значения другой увеличиваются. Значение коэффициента корреляции положительное, что означает наличие прямой связи между двумя переменными. При отсутствии связи значение коэффициента корреляции равно нулю.

В результате рассмотрения зависимости за 2021 г, представленной на рисунке 2.2, корреляционный коэффициент составил -0,92. В более узких периодах, например внутри суток, этот коэффициент показывает наличие отрицательной зависимости между электропотреблением и температурой наружного воздуха, как показан на рисунке 2.3. Видно, что имеется тесная взаимосвязь электропотребления с температурой наружного воздуха для ЦЭС Монголии.




Рисунок 2.3 - Корреляционная матрица

Стоит отметить, что температуру наружного воздуха можно считать универсальным метеорологическим фактором, поскольку любые изменения метеоусловий, в том числе облачность, радиационная обстановка, осадки и другие, приводят к изменению суточного хода температуры наружного воздуха. Отсюда можно сделать вывод о том, что влияние температуры воздуха необходимо учитывать при прогнозировании суточного графика нагрузки и за счет включения этого фактора модель исключает необходимость учета целого ряда дополнительных метеорологических факторов.

2.1.2 Методика, основанная на линейной регрессии

Так как любая энергосистема имеет свои особенности, необходимо рассматривать информацию за достаточно длительный период времени. Практически доказано, что для создания моделей электропотребления ЭЭС достаточно данных за предыдущие 30 дней.

Математическая формулировка. Суточный график нагрузки ЭЭС характеризуется нерегулярной и регулярной компонентами [105, 106]. Регулярная составляющая для каждого суточного графика нагрузки в ретроспективе рассчитывается за счет усреднения их значения.

$$P_{\text{ср}}^{\phi} = \frac{1}{24} \sum_{t=0}^{23} P_t ; \quad (2.2)$$

где $P_{\text{ср}}^{\phi}$ – фактический регулярный компонент; P_t – потребление электроэнергии каждого часа.

Построение модели регулярных компонентов суточных графиков нагрузки позволяет определить тенденцию электропотребления. С применением линейной регрессии можно получить математическую модель в виде следующего уравнения. Достоверность построенной модели также

оценивается коэффициентом детерминации R^2 . Если $R^2 > 0,6$, то можно считать модель достоверной.

$$P_{\text{ст}} = ax + b ; \quad (2.3)$$

где $P_{\text{ст}}$ – среднесуточная нагрузка; x – номер дня временного ряда; a , b – коэффициенты регрессии.

Конфигурация суточного графика нагрузки формируется путем усреднения всех суточных графиков нагрузки за период исследуемой ретроспективы с исключением нерабочих дней, так как их графики формируются иначе, чем в рабочие дни.

$$P_j = \frac{1}{N} \sum_{i=1}^N P_{ij} ; \quad (2.4)$$

где P_j – нагрузка в j -й час прогнозируемого дня; N – число выборок временного ряда.

Далее необходимо рассчитать регулярную составляющую для полученной конфигурации графика нагрузки следующим образом:

$$P'_{\text{ср}} = \frac{1}{24} \sum_{j=0}^{23} P_j ; \quad (2.5)$$

где $P'_{\text{ср}}$ – среднесуточная нагрузка полученного суточного графика.

Разделив значение каждого часа конфигурации на полученную среднесуточную нагрузку, график представляется в относительных единицах.

$$P_j^{\text{norm}} = \frac{P_j}{P'_{\text{ср}}} ; \quad (2.6)$$

где P_j^{norm} – нагрузка в j -й час в относительных единицах.

Прогноз суточного графика нагрузки формируется за счет умножения его значения в относительных единицах на среднее значение, вычисленное с помощью линейного уравнения.

$$P_{kj} = P_j^{\text{norm}} \cdot P_t ; \quad (2.7)$$

где P_{kj} – нагрузка в j -й час прогнозного графика; P_t – среднесуточная

нагрузка, рассчитанная по линейному уравнению.

При прогнозировании суточного графика нагрузки необходимо учитывать поправки на минимальную и максимальную нагрузки, так как от них напрямую зависит качество планирования режимов и надежность работы ЭЭС. Эти значения полученного графика нагрузки заменяются значениями, которые были рассчитаны методом линейной регрессии. Стоит отметить, что нерабочие дни исключены из расчета, так как они искажают тенденцию в ретроспективе.

$$j_{\max} = \arg \max_j (P'_{kj}) ; \quad (2.8)$$

$$j_{\min} = \arg \min_j (P'_{kj}) ; \quad (2.9)$$

где $j_{\max}$ – номер часа с максимальной нагрузкой; $j_{\min}$ – номер часа с минимальной нагрузкой; P'_{kj} – нагрузка в j -й час прогнозного графика.

$$P'_{kj_{\max}} = P_k^{\max} ; \quad (2.10)$$

$$P'_{kj_{\min}} = P_k^{\min} ; \quad (2.11)$$

где $P_k^{\max}$ – максимальная нагрузка, рассчитанная по линейному тренду; $P_k^{\min}$ – минимальная нагрузка, рассчитанная по линейному тренду.

При учете погодных условий, в частности температуры воздуха, применяется коэффициент K , отражающий влияние общих метеофакторов на электропотребление. Этот коэффициент помогает установить линейную взаимосвязь между отклонением нагрузки от среднего значения $P_{\text{ср}}$ и отклонением температуры воздуха от ее среднего значения $M_{\text{ср}}$ на 1°C [106]:

$$K = \left| \frac{1}{NM_{\text{ср}}} \sum_{i=1}^N \sigma P_i \right| ; \quad (2.12)$$

где N – количество выборок в временном ряде; $M_{\text{ср}}$ – среднее значение метеофакторов временного ряда; σP_i – нерегулярная составляющая потребления (отклонение от среднесуточной нагрузки).

Изменения в потреблении электроэнергии существенно зависят от

температуры воздуха, наблюдаемой в течение последних нескольких дней. Как правило, достаточно использование трех дней – текущего, вчерашнего и позавчерашнего. Для более точного учета температуры воздуха может использоваться так называемую «эффективную температуру», которая позволяет учесть запаздывание влияния этого фактора. Уравнение изменения температуры прогнозируемого дня выглядит следующим образом:

$$T_3(n) = a_1 T(n) + a_2 T(n - 1) + a_3 T(n - 2); \quad (2.13)$$

где $T(n)$, $T(n - 1)$, $T(n - 2)$ – соответственно температуры в прогнозный день, вчерашний и последующие; a_1 , a_2 , a_3 – весовые коэффициенты в зимний период составляют 0.5, 0.3, 0.2, в летний период – 0.7, 0.2, 0.1.

Поправка рассчитывается путем умножения изменения температуры на коэффициент влияния:

$$P_{\pi} = K T_3(n); \quad (2.14)$$

где P_{π} – поправка на температуру наружного воздуха; K – коэффициент влияния; $T_3(n)$ – изменение температуры наружного воздуха.

$$P'_{kj} = P_{kj} \pm P_{\pi}; \quad (2.15)$$

где P_{kj} – нагрузка в j -й час прогнозного графика; P_{π} – поправка на температуру наружного воздуха; P'_{kj} – нагрузка в j -й час после внесения поправки температуры.

Блок схема реализации методики, основанной на линейной регрессии, показана на рисунке 2.4.

Результаты. Начальным этапом прогнозирования является выявление тенденций на основе данных предыдущего месяца. Обычно, тенденция потребления электроэнергии подвержена искажению из-за факторов, связанных с нерабочими днями, так как их график отличается от будних дней. В связи с этим были проведены отдельные исследования с учетом и без учета нерабочих дней. Для создания математической модели использовался график, сформированный на основе регулярных компонентов временного ряда. На рисунке 2.5 представлен пример для одного из дней.




Рисунок 2.4 - Блок-схема реализации методики, основанной на линейной регрессии




Рисунок 2.5 - Пример графика среднесуточной нагрузки и тренд

Для определения среднесуточной нагрузки в прогнозируемый день было использовано линейное уравнение, описывающее тренд. После этого, согласно описанной ранее методике, был сформирован суточный график нагрузки для прогнозируемого дня без внесения корректировок. В качестве примера были проанализированы 12 суточных графиков нагрузки, случайно отобранных из каждого месяца, и результаты представлены в таблице 2.1. Среднее значение коэффициента детерминации R^2 оказалось недостаточным в обоих случаях, однако точность прогноза улучшилась при учете нерабочих дней. Это свидетельствует о том, что полагаться исключительно на тренд временного ряда может привести к значительным ошибкам. Таким образом, для повышения точности прогноза необходимо вводить дополнительные корректировки, учитывающие факторы, влияющие на потребление электроэнергии.

Таблица 2.1 – Результаты прогнозирования по тренду среднесуточной нагрузки

	С исключением нерабочих дней			С учетом нерабочих дней		
	R^2	MAE [MBm]	MAPE [%]	R^2	MAE [MBm]	MAPE [%]
1	0,21	24,74	2,40	0,18	22,27	2,19
2	0,0003	22,37	2,25	0,003	16,85	1,72
3	0,11	31,18	3,10	0,03	32,37	3,61
4	0,76	24,32	3,08	0,82	14,08	1,80
5	0,36	28,19	4,01	0,44	26,81	3,79
6	0,16	12,04	1,62	0,24	11,35	1,54
7	0,31	10,07	1,42	0,23	11,47	1,56
8	0,3	35,53	4,67	0,03	19,69	2,87
9	0,83	22,80	2,91	0,74	23,98	3,06
10	0,89	45,22	4,54	0,88	42,17	4,26
11	0,67	22,43	2,25	0,54	20,24	2,05
12	0,67	33,71	2,75	0,57	46,72	3,81
Результат	0,43	26,05	2,92	0,39	24,00	2,68

Примечание: R^2 – коэффициент детерминации; MAE – среднее по модулю ошибки; MAPE – среднее по модулю ошибки в процентах.

Стоит отметить, что при учете большого количества выходных или

праздничных дней возникает большая погрешность. Анализы также показали, что если во временной ряд входят дни с авариями и плановыми ремонтами, ограничившими электроснабжение потребителей, то погрешность прогнозирования возрастает. Варианты без исключения нерабочих дней, которые не продолжаются несколько дней, показывают меньшую погрешность прогнозирования, т.е. для ЦЭС Монголии этот вариант подходит в поставленной задаче.

Учет поправок на максимальную и минимальную нагрузки играет важную роль при планировании режимов ЭЭС, как сказано выше. Эти экстремумы полученного графика были заменены значениями, которые рассчитывались с помощью линейной регрессии. Результаты после учета этой поправки представлены в таблице 2.2.

Таблица 2.2 – Результаты прогнозирования с учетом максимальной и минимальной нагрузки

	С исключением нерабочих дней		С учетом нерабочих дней	
	Без поправки	С учетом $P_{\max}/P_{\min}$	Без поправки	С учетом $P_{\max}/P_{\min}$
	<i>MAPE – среднее по модулю ошибки в процентах, [%]</i>			
1	2,4	2,34	2,19	2,12
2	2,25	2,18	1,72	1,64
3	3,1	3,14	3,61	3,68
4	3,08	2,94	1,8	1,71
5	4,01	3,99	3,79	3,77
6	1,62	1,69	1,54	1,61
7	1,42	1,57	1,56	1,57
8	4,67	4,45	2,87	2,76
9	2,91	2,24	3,06	3,00
10	4,54	4,48	4,26	4,20
11	2,25	2,22	2,05	2,00
12	2,75	2,76	3,81	3,81
Результат	2,92	2,83	2,68	2,65

Из таблицы 2.2 видно, что внесенные изменения, касающиеся максимальных и минимальных нагрузок, способствуют снижению ошибок в

прогнозировании суточного графика нагрузки в обоих случаях. Кроме того, вариант, учитывающий нерабочие дни, демонстрирует наилучшие результаты, что подтверждает его эффективность для прогнозирования суточного графика нагрузки ЦЭС Монголии.

Зависимость между потреблением электроэнергии и температурой воздуха была исследована также двумя способами. В таблице 2.3 приведены результаты прогнозирования с учетом изменений температуры воздуха.

Таблица 2.3 – Результаты прогнозирования с учетом температуры наружного воздуха

	С исключением нерабочих дней		С учетом нерабочих дней	
	При расчете зависимости между метеофакторами и потреблением			
	Без нерабочих дней	С нерабочими днями	Без нерабочих дней	С нерабочими днями
	MAPE – среднее по модулю ошибки в процентах, [%]			
1	2,29	1,53	2,07	1,57
2	1,84	1,92	1,58	1,59
3	2,93	3,00	3,48	3,54
4	2,83	2,64	1,42	1,46
5	3,03	2,56	3,52	2,83
6	1,68	1,67	1,64	1,66
7	1,52	1,50	1,36	1,42
8	4,33	4,68	2,75	2,83
9	2,10	2,16	2,80	2,89
10	3,53	3,61	3,65	3,76
11	1,11	1,29	1,36	1,41
12	1,84	1,89	2,32	2,37
Результат	2,47	2,37	2,33	2,26

В таблице 2.4 и на рисунке 2.6 приведены итоговые результаты по применению предложенной методики на основе линейной регрессии. Базовая модель, исключая нетипичные дни и не имеющая поправок, показывает среднюю погрешность в 2,92 %. Включение нетипичных дней в построение тренда снижает погрешность до 2,68 %. Дополнительные поправки на минимальную и максимальную нагрузку уменьшают погрешность до 2,65 %. Учет температуры воздуха как общего метеофактора также позволяет

снизить ошибку до 2,47 %.

Таблица 2.4 – Итоговые результаты

№	Варианты, проведенные эксперименты		Погрешность	
			MAE [МВт]	MAPE [%]
1	Определение тренда без учета нерабочих дней	Без поправки	26,05	2,92
2		С учётом минимальной и максимальной нагрузки	25,32	2,83
3		С учётом метеофакторов при расчете исключения нерабочих дней	21,25	2,47
4		С учётом метеофакторов по всем дням	20,62	2,37
5	Определение тренда с учетом нерабочих дней	Без поправки	24,00	2,68
6		С учётом минимальной и максимальной нагрузки	23,85	2,65
7		С учётом метеофакторов при расчете исключения нерабочих дней	20,70	2,33
8		С учётом метеофакторов по всем дням	19,66	2,26

Примечание: MAE – среднее по модулю ошибки; MAPE – среднее по модулю ошибки в процентах.




Рисунок 2.6 - Гистограмма итоговых результатов

Применение вышеперечисленных модификаций в комплексе позволяет добиться снижения ошибки до 2,26 %. В итоге, снижение ошибки составило 0,66 процентного пункта (п.п.), что соответствует 22 %.

Экспериментально выявлены следующие недостатки. Тенденция временного ряда не может быть определена корректно при включении дней с авариями, ремонтами и многодневными выходными. Ненадежный тренд снижает эффективность прогнозирования. Поправка на температуру воздуха не учитывается, когда ее среднее значение не достигает единицы. Предлагаемая методика [112] позволяет выполнять прогнозирование суточного графика нагрузки для рабочих дней.

2.1.3 Применение интегрированной модели авторегрессии ARIMA

Для подтверждения предыдущей методики прогнозирования суточного графика нагрузки было проведено исследование по применению интегрированной модели авторегрессии скользящего среднего (ARIMA) [113]. Блок схема модели ARIMA показана на рисунке 2.7.




Рисунок 2.7 - Блок схема интегрированной модели авторегрессии и скользящего среднего

Любая ретроспектива имеет характер нестационарности, так как на форму суточных графиков нагрузки, входящих во временные ряды, влияют некоторые факторы. Следовательно, по регламенту анализа данной модели необходимо преобразовать графики нагрузки к стационарному ряду. В качестве примера, на рисунке 2.8 частично показан временной ряд исходных данных.



Рисунок 2.8 - Пример временного ряда исходных данных

После дифференцирования временной ряд приводится к следующему образу без тренда и сезонности, как изображено на рис. 2.9.



Рисунок 2.9 - Преобразованный временной ряд без тенденции

Исходные данные разделяются на выборки обучения и тестирования. В качестве выборки обучения выбраны данные потребления по часам за последние 30 дней до прогнозного дня. На обучающей выборке был проведен анализ авторегрессии и скользящего среднего, после этого была построена

модель временного ряда. На рисунке 2.10 показано сопоставление временных рядов, созданных на основе модели и фактических данных.



Рисунок 2.10 - Результаты моделирования временного ряда

Результаты. По построенной модели спрогнозированы суточные графики нагрузки прогнозных дней, которые выбраны случайным образом из каждого месяца. В таблице 2.5 приведены результаты двух статистических методов для сравнения.


Таблица 2.5 – Результаты классических методов прогнозирования

	Методика на основе линейной регрессии /без поправок/		ARIMA	
	MAE [MBm]	MAPE [%]	MAE [MBm]	MAPE [%]
1	22,27	2,19	19,90	1,90
2	16,85	1,72	33,70	3,05
3	32,37	3,61	25,86	2,64
4	14,08	1,80	20,06	2,22
5	26,81	3,79	28,26	3,88
6	11,35	1,54	28,25	4,06
7	11,47	1,56	19,91	3,05
8	19,69	2,87	15,06	2,08
9	23,98	3,06	17,21	2,14
10	42,17	4,26	21,81	2,46
11	20,24	2,05	18,61	1,93
12	46,72	3,81	17,39	1,66
Результат	24,00	2,68	22,17	2,59

Поскольку регрессионный анализ фокусируется исключительно на взаимосвязи между двумя признаками, традиционные методы не способны учитывать дополнительные факторы, которые могут влиять на характер потребления электроэнергии. Для повышения точности прогноза эти внешние факторы, например, температура воздуха, должны рассматриваться отдельно. Таким образом, требуется большой объем ручной работы, что приводит к снижению достоверности модели.

2.1.4 Применение ансамблевых моделей машинного обучения

Блок схемы. На рисунке 2.11 показаны блок–схемы ансамблевых алгоритмов машинного обучения. В случае применения случайного леса каждый регрессор строится параллельно, так что они независимы друг от друга. Этот метод агрегирования результатов относится к методу беггинга (*bagging*). Отличие бустинга (*boosting*) состоит в том, что каждый регрессор строится последовательно и каждый новый зависит от текущих результатов предыдущих регрессоров, объединенных в модель [54].






Рисунок 2.11 - Блок схема принципа ансамблевых алгоритмов. А) случайный лес, Б) адаптивный и экстремальный бустинг

В случае применения случайного леса каждый регрессор строится параллельно, так как они независимы друг от друга. Данный метод агрегирования результатов относится к методу беггинга (*bagging*). Отличие бустинга (*boosting*) состоит в том, что каждый регрессор строится последовательно и каждый новый зависит от текущих результатов предыдущих регрессоров, объединенных в модель [54]. На рисунке 2.12 и в таблице 2.6 представлена часть выборки исходных данных.

year	month	day	time	wd	wh	temp	hum	wind	load-7	load-6	...	load-2	load-1	load
2019	1	8	0	2	1	-33.0	67.0	3	947.0	894.0	...	898.0	899.0	917
2019	1	8	1	3	1	-31.0	68.0	5	880.0	838.0	...	844.0	836.0	850
2019	1	8	2	3	1	-29.0	68.0	4	825.0	825.0	...	814.0	830.0	819
...														
2021	12	31	21	6	1	-15.0	72.0	11	1257.0	1261.0	...	1240.0	1241.0	1187
2021	12	31	22	6	1	-16.0	72.0	11	1216.0	1212.0	...	1219.0	1196.0	1173
2021	12	31	23	6	1	-17.0	78.0	9	1162.0	1141.0	...	1148.0	1120.0	1138

Рисунок 2.12 - Часть выборки исходных данных

Таблица 2.6 – Выборки исходных данных и прогнозные данные

Число	<i>time</i>	0:00	01:00	...	23:00
Нагрузки 7 суток назад	<i>load-7</i>	X_1	X_2	...	X_{24}
Нагрузки 6 суток назад	<i>load-6</i>	X_{25}	X_{26}	...	X_{48}
Нагрузки 5 суток назад	<i>load-5</i>	X_{49}	X_{50}	...	X_{72}
...	...	...	...	...	...
Нагрузки текущих суток	<i>load-1</i>	X_{145}	X_{146}	...	X_{168}
Температура воздуха	<i>temp</i>	x_1	x_2	...	x_{24}
Влажность воздуха	<i>hum</i>	x_{25}	x_{26}	...	x_{48}
Скорость ветра	<i>wind</i>	x_{49}	x_{50}	...	x_{72}
Тип дня	<i>wh</i>	X'_1			
День недели	<i>wd</i>	X'_2			
Прогноз на сутки вперед	<i>load</i>	Y_1	Y_2	...	Y_{24}

В качестве входных переменных принимается ряд внутренних признаков, в том числе почасовые нагрузки текущего дня (*load*) и нагрузки на *i*-ые сутки вперед (*load-i*). В дополнение к ним алгоритм также учитывает следующие внешние факторы: день недели (*wd*), тип дня (*wh*), число (*time*), влажность воздуха (*hum*), скорость ветра (*wind*) и температуру воздуха (*temp*). Авторы, занимающиеся краткосрочным прогнозированием, в достаточной степени подчеркивают актуальность учета вышеупомянутых переменных в своих работах. В поставленной задаче настоящей главы влияние этих переменных было определено посредством корреляционного анализа, результаты которого представлены на рисунке 2.13.




Рисунок 2.13 - Корреляционная матрица

На рисунке 2.13 видно, что электропотребление прогнозируемого дня существенно зависит от графиков нагрузки предыдущей недели. Корреляционный коэффициент между температурой воздуха и электропотреблением варьируется от -0.56 до -0.59, что доказывает необходимость учета температуры воздуха. Внешние факторы не оказывают существенного влияния на электропотребление по сравнению с другими признаками. Таким образом, вышеперечисленные признаки играют определенную роль, в соответствии с их учетом, при построении многофакторной модели суточного графика нагрузки.

Как правило, исходные данные были разделены на обучающую и тестовую подвыборки в соотношении 66 к 33. Алгоритм выполняет регрессионный анализ на обучающей подвыборке и формирует список наиболее значимых признаков, который показан на рисунке 2.14. Иначе говоря, роль исходных переменных определяется в ходе обучения алгоритма.




Рисунок 2.14 - Роль переменных в процессе обучения алгоритмов

Рисунок 2.14 показывает, что конфигурация суточного графика нагрузки прогнозируемых дней зависят от текущего и предыдущего графиков. Внешние факторы, такие как температура воздуха (*temp*), тип дня (*wh*) и день недели (*wd*), также оказывает определенное влияние на конфигурацию суточного графика нагрузки, но не более чем внутренние факторы. Следует отметить, что такое поведение также наблюдалось при использовании методики, основанной на линейной регрессии в работе [112].

При построении алгоритмов, наиболее важной задачей является определение количества (*n_estimators*) и глубины (*max_depth*) деревьев решений, которые должны быть включены в состав ансамблевых моделей. Целью этой задачи является настройка гиперпараметров таким образом, чтобы эффективность модели была максимально высокой, уменьшив сложность алгоритма. Выбор этих гиперпараметров значительно влияет на объем алгоритма и вероятность корректной работы модели. На рисунке 2.15 представлена зависимость оценки модели от гиперпараметров.




Рисунок 2.15 - Зависимость вероятности корректной работы модели от глубины и количества деревьев

Для настройки гиперпараметров (глубины и количества деревьев) ансамблевых моделей используется функция *GridSearchCV*, позволяющая оптимизировать параметры модели в программном пакете *Python 3.0*. В диссертационной работе гиперпараметры также настраивались с помощью

этой функции.

Отклонение прогнозов модели от фактических значений оценивалась с помощью показателей средней по модулю ошибки (*mean absolute error, MAE*) (1.29) и средней по модулю ошибки в процентах (*mean absolute percentage error, MAPE*) (1.30). Для тестовой выборки *MAE* составила от 18,71 до 19,64 МВт при построении с применением различных ансамблевых алгоритмов, а *MAPE* – от 2,41 % до 2,50 %. В таблице 2.7 приведены оценки корректности модели и гиперпараметры ансамблевых алгоритмов. В ходе эксперимента было установлено, что ансамблевые модели обладают достаточно высокой точностью, в том числе наибольшую точность имеет алгоритм экстремального бустинга.

Таблица 2.7 – Оценка вероятности моделей и гиперпараметры алгоритма

Модели	Глубина деревьев	Количество деревьев	<i>MAE [MBm]</i>	<i>MAPE [%]</i>
<i>RF</i>	12	100	19,3	2,6
<i>AD</i>			19,6	2,5
<i>XG</i>			18,7	2,4

На рисунке 2.16 представлен фрагмент тестовой выборки модели экстремального градиентного бустинга (*XGBoost*).




Рисунок 2.16 - Фрагмент осциллограммы процесса тестирования модели

В качестве примера использования ансамблевых алгоритмов в рассматриваемой задаче осуществлено прогнозирование 12 суточных графиков нагрузки. Сутки, для которых выполняется прогнозирование, выбирались случайным образом из каждого месяца. На рисунке 2.17 представлены суточные графики нагрузки, спрогнозированные алгоритмом экстремального градиентного бустинга (XGBoost). В работах [114, 115] приведены результаты исследований, посвящённых применению ансамблевых моделей машинного обучения.




Рисунок 2.17 - Результаты прогнозирования суточных графиков нагрузки с использованием модели экстремального градиентного бустинга

Ансамблевые алгоритмы машинного обучения предоставляют возможность прогнозировать суточные графики нагрузки как для рабочих, так и нерабочих дней. Данные алгоритмы также позволяют одновременно рассматривать несколько признаков как внешних, так и внутренних при построении моделей.

В таблице 2.8 и на рисунке 2.18 приведены результаты применения предложенных алгоритмов машинного обучения и классических методов, таких как линейная регрессия и интегрированная модель авторегрессии скользящего среднего (ARIMA). Видно, что при использовании методов машинного обучения достигается наибольшая точность прогнозирования. При этом средняя погрешность составила от 1.25 до 1.45 %.

Таблица 2.8 – Результаты применения классических методов и ансамблевых алгоритмов машинного обучения

	Классические методы		Методы машинного обучения		
	ARIMA	Линейная регрессия с учетом поправок	Random Forest	Ada boost	XG boost
	MAPE [%]				
1	1,90	1,57	0,92	1,04	0,55
2	3,05	1,59	1,63	1,33	1,11
3	2,64	3,54	2,66	1,23	0,97
4	2,22	1,46	1,32	1,26	1,02
5	3,88	2,83	2,26	1,47	1,26
6	4,06	1,66	1,17	1,80	1,70
7	3,05	1,42	1,66	1,31	1,06
8	2,08	2,83	1,21	2,64	1,24
9	2,14	2,89	1,08	2,17	2,09
10	2,46	3,76	1,27	1,93	1,79
11	1,93	1,41	1,37	1,58	1,48
12	1,66	2,37	0,87	0,96	0,76
Результат	2,59	2,26	1,45	1,56	1,25




Рисунок 2.18 - Результаты прогнозирования суточных графиков нагрузки

2.2 Прогнозирование нагрузки в узлах энергосистемы

Центральная энергосистема (ЦЭС) Монголии состоит из пяти энергорайонов, в том числе Улан-Баторского (зона энергоснабжения «U»), Эрдэнэт-Булганского (зона энергоснабжения «H»), Дархан-Селенгинского (зона энергоснабжения «T»), Багануур-Чойрского (зона энергоснабжения «B») и Гови (зона энергоснабжения «G»). На рисунке 2.19 представлена структурная схема рассматриваемой энергосистемы.

Поскольку ЦЭС Монголии характеризуется иерархической структурой с узлами, отличающимися по потребляемой мощности, как правило,

суточные графики нагрузки для каждой подстанции или энергорайона могут быть определены с помощью ранговых моделей.




Рисунок 2.19 - Структурная схема ЦЭС Монголии

2.2.1 Восстановление суточного графика нагрузки в узлах

В ЦЭС Монголии входят 52 узловые подстанции. За счет суммирования фактических данных соответствующих подстанций были

рассчитаны суточные графики нагрузки каждого энергорайона, как представлено на рисунке 2.20.




Рисунок 2.20 - Суточные графики нагрузки энергорайонов ЦЭС Монголии

Видно, что в силу особенностей и состава потребителей графики нагрузки каждого энергорайона имеют различную конфигурацию. Используя графики нагрузки, представленные на рисунке 2.20, можно построить достаточно длинные временные ряды электропотребления в исследуемых зонах энергоснабжения.

За счет представления полученных графиков нагрузки в относительных единицах построены годовые временные ряды для каждой зоны энергоснабжения, которые отражают различия в формах суточных графиков в каждом месяце. Путем умножения на максимальную нагрузку каждого дня, зарегистрированную в системе SCADA, получены временные ряды нагрузки каждой зоны за год, которые приведены на рисунке 2.21. Следует отметить, что такой принцип моделирования был создан за счет использования тестовой системы *IEEE* в работах [116, 117].




Рисунок 2.21 - Графики суточной максимальной нагрузки и почасового потребления электроэнергии в зонах энергоснабжения в течение года

2.2.2 Применение ранговых моделей и результаты

С использованием полученных временных рядов для энергорайонов и фактического временного ряда общего потребления ЦЭС Монголии определены коэффициенты участия для каждого энергорайона за счет применения ранговых моделей [114, 115, 118]. На рисунке 2.22 и в таблице 2.9. приведены ранговые коэффициенты для энергорайонов.




Рисунок 2.22 - Зависимость потребления энергорайонов и ранговых коэффициентов от времени

На рисунке 2.22 показано, что большого диапазона в изменении ранговых коэффициентов не наблюдается и ранговые порядки в исследуемом временном ряде не меняются. Оценка достоверности ранговых моделей представлена на рисунке 2.23.




Рисунок 2.23 - Ранговые модели

Как видно из рисунка 2.23, коэффициенты детерминации R^2 близки к единице, следовательно, для энергорайонов получены достаточно достоверные модели. Таким образом, использование ранговых моделей в достаточной степени позволяет прогнозировать электропотребление для каждого энергорайонов.

Таблица 2.9 – Ранговые коэффициенты зон энергоснабжения

Наименование энергорайонов	Расчетное название	Ранговые номер	Средний коэффициент участия от общей, о.е.
Улан-Батор	U	I	0,54
Эрдэнэт – Булган	H	II	0,25
Дархан – Селенге	T	III	0,09
Багануур – Чойр	B	IV	0,08
Говь	G	V	0,02

С применением ансамблевых моделей машинного обучения суточные графики нагрузки ЦЭС были спрогнозированы со средней ошибкой, не превышающей 2,0 %, а суточные графики нагрузки каждого энергорайонов были построены за счет учета ранговых коэффициентов. На рисунке 2.24 представлены графики нагрузки ЦЭС и энергорайонов в качестве примера.




Рисунок 2.24 - Суточные графики нагрузки энергосистемы и зон энергоснабжения

Из графиков видно, что суточные графики нагрузки энергорайонов ЦЭС Монголии имеют различную конфигурацию вследствие изменения коэффициентов ранга за рассматриваемый период времени. Графики также представляют, как нагрузка влияет на форму суточного графики нагрузки ЭЭС. Сопоставление прогнозной и фактической нагрузки в каждом энергорайоне, а также численные результаты прогнозирования представлены на рисунке 2.25 и в таблице 2.10.




Рисунок 2.25 - Сопоставление прогнозов и фактических графиков нагрузки зон энергоснабжения

Таблица 2.10 – Итоговые результаты прогнозирования потребления в зонах энергоснабжения

Номер ранг	I, зона U		II, зона H		III, зона B		IV, зона T		V, зона G	
	MAE [МВт]	MAPE [%]	MAE [МВт]	MAPE [%]	MAE [МВт]	MAPE [%]	MAE [МВт]	MAPE [%]	MAE [МВт]	MAPE [%]
1	2,8	0,4	0,8	0,5	0,4	0,5	0,5	0,5	0,3	1,4
2	7,7	1,2	2,5	1,3	1,0	1,2	0,9	1,2	0,3	1,5
3	3,7	0,6	1,1	0,6	0,5	0,5	0,5	0,7	0,2	1,3
4	8,0	1,7	3,4	1,6	1,7	1,8	1,1	1,7	0,2	1,9
5	1,4	0,3	0,6	0,3	0,3	0,4	0,2	0,4	0,1	1,4
6	2,5	0,7	1,1	0,7	0,6	0,7	0,5	0,7	0,1	1,5
7	5,0	1,4	2,4	1,4	0,9	1,3	0,9	1,4	0,2	1,5
8	6,7	1,6	2,5	1,6	1,1	1,6	1,1	1,6	0,3	2,1
9	1,4	0,3	0,6	0,4	0,3	0,4	0,2	0,3	0,2	1,8
10	3,6	0,8	1,4	0,8	0,6	0,9	0,6	0,9	0,2	1,4
11	6,7	1,4	2,7	1,4	1,1	1,3	0,9	1,4	0,3	1,8
12	1,8	0,3	0,7	0,4	0,3	0,5	0,4	0,5	0,3	1,1
Результат	4,2	0,88	1,66	0,9	0,73	0,93	0,65	0,93	0,23	1,5

Результаты показывают, что модели нагрузки энергорайонов могут быть применены для расчета нормальных режимов ЦЭС Монголии, поскольку средняя погрешность моделей не превышает 2,0 %. С точки зрения зон энергоснабжения таким методом можно определить нагрузки подстанций, относящихся к этим зонам.

Выводы по главе 2

Изучены факторы, влияющие на электропотребление, в том числе метеорологические факторы и календарные особенности. Проведен ранговый анализ для установления долей узлов в общей нагрузке энергосистемы. В задаче прогнозирования потребления электроэнергии был использован ряд моделей, таких как линейная модель и модель авторегрессии (ARIMA), а также ансамблевые модели на основе машинного обучения. С помощью ранговых моделей построены графики нагрузки в узлах энергосистемы.

Выявлено, что реализация классических методов довольно проста, но они ограничены возможностью создания многофакторной модели из-за невозможности учета переменных. Требуется также большой объем ручной работы, и каждая поправка вносится отдельно. Таким образом, для устранения отмеченных выше недостатков необходимо применять метод машинного обучения, в том числе ансамблевых моделей.

В поставленной задаче использование ансамблевых моделей машинного обучения снизило погрешность классических методов с 2,26 до 1,25 %. Таким образом, снижение ошибки составило 1,01 п.п, или 44,7 %. Затем на основе прогноза суточного графика нагрузки энергосистемы с помощью ранговых моделей спрогнозированы нагрузки в узлах с погрешностью не более 2,0 %.

Предложено использовать ансамблевые алгоритмы машинного обучения, в том числе экстремального градиентного бустинга (*XGBoost*) для прогнозирования суточного графика нагрузки центральной энергосистемы Монголии. Показано, что в задаче моделирования нагрузки в узлах может быть использован метод ранговых моделей.

ГЛАВА 3 РАЗРАБОТКА МЕТОДОВ ПРОГНОЗИРОВАНИЯ СУТОЧНЫХ ГРАФИКОВ ГЕНЕРАЦИИ ВОЗОБНОВЛЯЕМЫХ ИСТОЧНИКОВ

Целью настоящей главы является разработка методов прогнозирования суточных графиков генерации возобновляемых источников энергии (ВИЭ), таких как ветровые и солнечные электростанции. Электроэнергия, вырабатываемая за счёт возобновляемых ресурсов, непосредственно зависит от таких факторов, как метеорологические условия, географическое расположение электростанции, сезонность, и другие [119, 120]. При прогнозировании суточных графиков учет этих факторов достаточно сложен из-за стохастических и хаотических характеристик энергоносителей [121]. При рассмотрении таких задач ансамблевые методы машинного обучения способны выявлять сложные нестационарные и нелинейные характеристики в ретроспективных данных, а также могут быть использованы в задачах прогнозирования суточной выработки ВИЭ.

В качестве исходной информации должны использоваться данные о суточных графиках генерации ВИЭ, вырабатывающих электроэнергию в Центральной энергосистеме (ЦЭС) Монголии, за период с 2019 по 2021 г. Должны учитываться также метеорологические данные, в том числе температура наружного воздуха, скорость ветра, освещенность, осадки и влажность.

3.1 Вопросы использования возобновляемой энергии

Традиционные источники теряют свою главную позицию в производстве энергии в связи с сокращением ресурсов и увеличением глобального потепления. Чрезмерное потребление ископаемого топлива также приведет к экологическому кризису. Сегодня использование

возобновляемой энергии стало перспективным направлением для сокращения вредных выбросов при производстве энергии. ВИЭ также активно растет на оптовых и розничных рынках электроэнергии по всему миру, причем наибольшее распространение получили ветровая и солнечная энергия как один из основных видов ВИЭ. Предполагается, что возобновляемая энергетика будет занимать значимое место в ближайшем будущем, особенно в развивающихся странах.

Вследствие растущего внедрения ВИЭ возникает дополнительная неопределенность со стороны генерации электроэнергии, что усложняет обеспечение баланса активной мощности ЭЭС. Таким образом, прогнозирование электроэнергии, вырабатываемой ВИЭ, играет значительную роль в обеспечении непрерывного контроля режимов ЭЭС и управления ими, в частности при планировании режимов ЭЭС непременно следует учитывать влияние ВИЭ [37, 39]. Точность прогнозирования генерации ВИЭ также служит повышению степени ее проникновения в электрические сети [48].

Количество электроэнергии, вырабатываемой ВИЭ, напрямую зависит от таких факторов, как метеорологические условия, географическое расположение электростанции, сезонность, и т.д. [119, 120]. В задаче прогнозирования, учет данных факторов достаточно сложен из-за стохастических и хаотических характеристик энергоносителей [121]. В научных исследованиях [37-45] предлагается ряд таких методов, как физические, статистические и гибридные или ансамблевые.

В целом физические методы определяют общий объем производства возобновляемой энергии, принимая во внимание числовую метеорологическую информацию, такую как температура, влажность, атмосферное давление, скорость ветра, освещенность, облачность и осадки [44]. В связи с трудностями предоставления метеорологических данных за короткие промежутки времени данные методы не рекомендуются в задачах краткосрочного прогнозирования.

Статистические методы являются целесообразным при решении задач краткосрочного прогнозирования. Они не требуют большого объема вышеуказанных физических или метеорологических данных и позволяют выявлять линейные и нелинейные зависимости между рассматриваемыми показателями в краткосрочной перспективе [122]. Модели авторегрессии, включая *ARMA*, *ARIMA* и *SARIMA*, могут быть применены для отслеживания поведения ВИЭ, имеющего линейную зависимость [123, 124].

Методы искусственного интеллекта, такие как метод опорных векторов [48, 49], нечеткая логика [40, 51, 52] и нейронные сети [55, 56], используются, если рассматриваемый временной ряд является нестационарным и нелинейным. Методы искусственного интеллекта позволяют компенсировать недостатки традиционных регрессионных методов и обрабатывать многомерные данные, так что они получили широкое применение в задачах краткосрочного прогнозирования выработки электроэнергии на основе ВИЭ [125].

Если применять статистические или физические методы отдельно, то они не могут полностью отразить сложные временные ряды возобновляемой энергии, хотя они обладают уникальными свойствами. В задачах краткосрочного прогнозирования гибридные методы становятся эффективным путем для учета стохастических характеристик ВИЭ. Таким образом, применение ансамблевых моделей, объединяющих несколько регрессоров, позволяет реализовать гибридные методики в задачах прогнозирования генерации ВИЭ.

В работах [126–129] предлагается модель авторегрессии для прогнозирования радиации солнца. Результаты верификации предложенной модели подтверждает ее применимость для краткосрочного прогнозирования прозрачности атмосферы и, следовательно, генерации солнечных электростанций. Авторы также отмечают, что повысить точность возможно с использованием интеллектуальных математических методов, таких как искусственные нейронные сети, генетические алгоритмы и другие.

Авторы работы [130] предложили несколько моделей прогнозирования временных рядов, построенных методами авторегрессии и нейронных сетей. Авторы использовали лишь данные о почасовой выработке, так как они содержат информации о солнечной радиации и местоположении. Сравнительное исследование показали, что нейронные сети более точны, чем статистические модели.

В работе [131] предложена модель прогнозирования почасовой генерации на сутки вперед для солнечной электростанции установленной мощностью 20 МВт. В качестве исходной информации выбраны данные о почасовой выработке. С помощью метода опорных векторов [47–49, 131] погодные условия классифицируются на четыре типа: ясный день, облачный день, туманный день и дождливый день. На основе прогноза погоды и соответствующей модели, построенной с помощью метода опорных векторов, была спрогнозирована выработка электроэнергии на солнечной электростанции.

В работах [132, 133] авторы предлагают использование ансамблевых моделей в задаче прогнозирования генерации солнечной электростанции. Стоит отметить, что предлагаемые ансамблевые модели используются на реальных объектах.

В работе [134] предлагается алгоритм опорных векторов в задаче преобразования скорость ветра в генерацию ветроагрегатов. В данной работе модель адаптивного бустинга используется в моделировании временных рядов скорости ветра. Таким образом, авторы считают, что комбинация алгоритмов адаптивного бустинга и опорных векторов относятся к гибридным методам и стало более эффективным путем для прогнозирования генерации ветровой электростанции.

В работе [52] предоставляется комбинированная методика на базе нечеткой логики и нейронных сетей для прогнозирования скорости ветра в краткосрочной перспективе. Основными факторами, влияющими на выработку электроэнергии ветряными электростанциями, являются такие

параметры, как температура воздуха, скорость ветра, плотность воздуха и атмосферное давление. Учет всех этих факторов даёт возможность повысить точность прогнозирования предлагаемой модели. Модель прогнозирования протестирована на четырех наборах данных, разделенных по сезонам года с помощью нечеткой логики. Предложенная модель прогнозирования реализована в пакете *MATLAB* и результаты показывают, что точность прогнозирования достаточно высокая.

В работе [135] метод опорных векторов выделяет сезонность из исходных временных рядов и генерация электроэнергии рассчитана с помощью искусственных нейронных сетей для каждого сезона. Ансамблевые модели машинного обучения также разработаны для решения поставленной задачи. Экспериментально установлено на основе полученных результатов, что сочетание опорных векторных машин и нейронных сетей позволяет сократить вычислительные работы и отфильтровать шумы в исходных временных рядах. В отражении нелинейных характеристик временных рядов скорости ветра, ансамблевые модели показывают свои преимущества.

В работе [136] предлагается использование гибридной модели, построенной из алгоритма адаптивного бустинга, нейронных сетей и вейвлет–пакетной декомпозиции, в задаче моделирования временных рядов скорости ветра. Для проведения экспериментов по прогнозированию приведены четыре различных временных ряда скорости ветра. В работе доказано, что ансамблевая модель является более точной чем одиночные модели.

L. Wang с соавторами [137] представляют модель адаптивного бустинга в задаче прогнозирования скорости ветра. Авторы сравнили модели прогнозирования на основе статистических методов и ансамблевого алгоритма. В этой работе использованы данные от семнадцати автоматических метеорологических станций установленных в бассейне реки Хэйхэ, четыре станции, расположенные в разных местах, были приняты для составления прогноза скорости ветра в различных временных масштабах.

Авторы [138] при оптимизации параметров роя частиц (*PSO*) в задаче прогнозирования почасового графика скорости ветра рассматривали использование экстремального градиентного бустинга, адаптивного бустинга и нейронных сетей. Для сравнения предложенных гибридных методов использованы различные показатели эффективности, тест Пирсона и диаграмма Тейлора. Результаты показали, что предложенные гибридные методы обеспечивают приемлемые результаты прогнозирования скорости ветра.

Авторы работы [139] предлагают гибридный алгоритм, основанный на методах вейвлет-преобразования и опорных векторов. Разработанный алгоритм был протестирован на практике и показал высокую точность и эффективность при краткосрочном прогнозировании скорости ветра. Начальная обработка исходных данных о скорости ветра осуществляется через вейвлет-преобразование. На обработанных данных обучается алгоритм опорных векторов для прогнозирования скорости ветра.

Известно, что классические методы ограничены в возможностях построения многофакторных моделей [33, 34, 38, 41, 46]. Поэтому их не рекомендуется использовать при прогнозировании суточного графика генерации ВИЭ. В приведенных выше работах утверждается, что если использовать только один метод прогнозирования, то случайные компоненты могут привести к снижению точности модели.

Аргументируется, также что многофакторные модели считаются более целесообразными при прогнозировании сложных временных рядов с учетом определенных внешних факторов. Таким образом, для достижения поставленных задач предполагается применение методов машинного обучения, в том числе ансамблевых алгоритмов.

3.2 Прогнозирование генерации ветровых электростанций

3.2.1 Характеристика генерации ветровых установок

Генерация ветроагрегатов зависит от скорости и направления ветра, поскольку они используют энергию ветра для выработки электроэнергии. Чем выше скорость ветра, тем больше энергии вырабатывается. Однако слишком высокие скорости ветра могут представлять угрозу для ветроагрегатов. Так, установлены предельные значения скорости ветра, при которых установки должны быть выведены из работы или зафлюгированы. Таким образом, оптимальные условия для выработки электроэнергии ветроагрегатами лежат, как правило, в диапазоне определенных скоростей ветра.

Зависимость выработки от скорости ветра позволяет проанализировать характер генерации ветроагрегата, представленный на рисунке 3.1 [140]. По оси абсцисс расположены три значения скорости ветра: минимальная V_{cut-in} , номинальная V_{rated} и критическая $V_{cut-out}$. График разделяется по этим значениям на четыре сегмента, каждый из которых имеет свою зависимость генерации от скорости ветра.




Рисунок 3.1 - График зависимости активной мощности ветроагрегата от скорости ветра

Когда скорость ветра V находится ниже минимальной V_{cut-in} или превышает критическую скорость $V_{cut-out}$, генерация составляет ноль. Если находится в сегменте $V_{rated} < V < V_{cut-out}$, генерация достигает номинальной мощности. Точки, расположенные между минимальной и номинальной скоростью, можно описать следующим выражением:

$$P = \frac{1}{2} C_p \rho \pi R^2 V^3; \quad (3.1)$$

при

$$V_{cut-in} < V < V_{rated}. \quad (3.2)$$

где V – скорость ветра; C_p – коэффициент турбины; ρ – плотность воздуха; R – радиус ротора турбины; P – генерация ветроагрегата.

Системы SCADA на ветропарках записывают обширные исторические данные о скорости ветра и выработке электроэнергии. Используя эти информации, можно строить графики, отображающие физическую связь между выработкой и скоростью ветра для соответствующих ветротурбин. На рисунке 3.2 показаны графики зависимостей для ветроэлектростанций, которые вырабатывают электроэнергию в ЦЭС Монголии.




Рисунок 3.2 - Графики зависимости ветроагрегатов

Однако из-за человеческих ошибок, сбоя датчиков или связи, а также ошибок оперативно-диспетчерского персонала эти данные могут содержать

большое количество аномальных значения. Таким образом, выделенным линиями на графиках определяются зависимости для каждой ветроэлектростанции.

3.2.2 Построение ансамблевых моделей и результаты

Предлагается применения ансамблевых моделей машинного обучения, включая случайный лес (*Random Forest*), экстремальный градиентный бустинг (*XGBoost*) и адаптивный бустинг (*AdaBoost*), в задаче прогнозирования скорости ветра в трех районах, где вырабатывают электроэнергию ветроэлектростанции с различными ветроагрегатами. Информация о рассматриваемых ветроэлектростанциях, вырабатывающих электроэнергию в ЦЭС Монголии, приведена в таблице 3.1.

Таблица 3.1 – Установленная мощность ветровых электростанций

Электростанции	Наименование в расчетах	Количество агрегатов	Установленная мощность, МВт
Сайншанд	ВЭС-3	25	55
Салхит	ВЭС-1	31	50
Цэций	ВЭС-2	25	50

Почасовые данные о генерации и скорости ветра записаны для вышеуказанных ветровых электростанций и взяты за период с 2019 по 2021 год в качестве исходных переменных. Данные о сезонности также учитываются в качестве дополнительных переменных, включая названия месяцев (*month*), дней (*day*) и часов (*hour*). Это позволит определить уровень изменения скорости ветра по месяцам, то есть при прогнозировании скорости ветра будет учитываться особенность сезона.

Алгоритм обучается на ретроспективных данных о скорости ветра за предыдущую неделю (*wind-i*). Весь набор переменных разделен на тестовый и обучающий наборы. Первые 70 % предназначены для обучения, а

остальные 30 % – для тестирования. В таблице 3.2 приведены входные и выходные переменные. Рисунок 3.3 представляет роль этих признаков при построении ансамблевых моделей, упомянутых выше.

Таблица 3.2 – Выборки исходных и выходных данных

час	<i>hour</i>	0:00	01:00	...	23:00
скорость ветра 7 суток назад	<i>wind-7</i>	X_1	X_2	...	X_{24}
скорость ветра 6 суток назад	<i>wind -6</i>	X_{25}	X_{26}	...	X_{48}
скорость ветра 5 суток назад	<i>wind -5</i>	X_{49}	X_{50}	...	X_{72}
...	...	...	...	...	...
скорость ветра текущих суток	<i>wind-1</i>	X_{145}	X_{146}	...	X_{168}
номер месяца	<i>month</i>	X'_1			
номер дня	<i>day</i>	X'_2			
прогноз скорости ветра на сутки вперед	<i>wind</i>	Y_1	Y_2	...	Y_{24}




Рисунок 3.3 - Роль переменных при построении модели прогнозирования скорости ветра

Сложнейшей задачей при построении моделей является настройка гиперпараметров, в том числе количества ($n_estimators$) и глубины (max_depth) регрессоров, отвечающих за достоверность модели R^2 . Рисунок

3.4 представляет коэффициент детерминации моделей R^2 от глубины регрессоров.




Рисунок 3.4 - Зависимость вероятности модели от глубины деревьев

Функция *GridSearchCV* (библиотеке *sklearn*) настраивает гиперпараметры ансамблевых моделей. Было принято решение с помощью данной функции, что число регрессоров (*n_estimators*) равно 100, а глубина регрессоров (*max_depth*) – 20, поскольку превышение этих значений практически не влияют на оценку моделей.

Гиперпараметры и оценки моделей показаны в таблице 3.3. Примеры отрезка процесса тестирования каждой модели также представляется на рисунке 3.5.

Таблица 3.3 – Достоверности моделей

	Гиперпараметры		Салхит		Цэций		Сайншанд	
	Глубина деревьев	Количество деревьев	MAE, м/с	nMAE, %	MAE, м/с	nMAE, %	MAE, м/с	nMAE, %
RF	20	100	1,33	15,81	2,19	17,25	1,44	17,71
XG			0,68	8,16	0,70	8,66	0,74	9,14
AD			0,63	7,49	0,67	8,46	0,68	8,40

Таблица 3.3 и рисунок 3.5 показывают, что модели, построенные с использованием алгоритмов экстремального градиентного бустинга (*XGB*) и адаптивного бустинга (*Ada*), имеют меньшую ошибку чем модель случайного леса (*RF*).




Рисунок 3.5 - Отрезок процесса тестирования модели

Стоит отметить, что ансамблевые модели были оценены по следующим показателям: средняя погрешность по модулю (*Mean Absolute Error, MAE*) и нормализованная средняя ошибка по модулю в процентах (*Normalized MAE, nMAE*).

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| ; \quad (3.3)$$

$$nMAE = MAE: \frac{1}{N} \sum_{i=1}^N y_i \cdot 100 \quad ; \quad (3.4)$$

где N – размер выборки, y_i – фактическое значение i -го элемента выборки, $\hat{y}_i$ – прогнозируемое значение i -го элемента выборки.

Временные ряды выработки электроэнергии на трех ветропарках прогнозировались на суточном интервале на основе моделей скорости ветра, построенных с помощью адаптивного алгоритма бустинга, и зависимостей выработки от скорости ветра (на рисунке 3.2). Результаты прогнозирования суточных графиков генерации показаны в таблице 3.4.

Таблица 3.4 – Результаты прогнозирования выработки ВЭС

	Салхит		Цэций		Сайншанд	
	MAE, МВт	nMAE, %	MAE, МВт	nMAE, %	MAE, МВт	nMAE, %
1	0,78	2,18	3,52	7,30	4,35	17,09
2	0,58	1,63	4,15	8,45	2,52	5,05
3	7,96	20,54	0,63	1,26	1,07	2,35
4	1,79	14,50	6,85	31,17	5,97	29,10
5	3,01	11,45	1,97	5,08	6,82	19,77
6	0,82	22,29	3,12	7,99	0,85	19,30
7	1,22	6,80	3,66	25,25	1,73	7,17
8	1,49	4,48	2,13	4,17	6,42	15,34
9	2,17	16,65	2,75	13,32	1,74	10,91
10	4,43	22,56	6,46	19,91	3,35	6,73
Результат	2,42	12,30	3,52	12,39	3,48	13,28

Средняя ошибка по модулю прогнозирования (MAE) находилась в пределах от 2,4 до 3,5 МВт; в процентах (нормализованная средняя ошибка по модулю – $nMAE$) – от 12,3 до 13,3 %. Следовательно, ошибка прогнозирования занимает от 5,0 до 7,0 % от установленной мощности соответствующих ветропарков.

В качестве примера на рисунке 3.6 показано сопоставление прогнозного и фактического суточного графика генерации для рассматриваемых ветровых электростанций на 07.03.2021.




Рисунок 3.6 - Сопоставление прогнозов и фактических графиков генерации ветровых электростанций

3.3 Прогнозирование генерации солнечных электростанций

3.3.1 Построение ансамблевых моделей

Производство солнечной электростанции непосредственно связано с солнечной радиацией, которая состоит из детерминированных и стохастических компонентов. К детерминированным компонентам относятся сезонные и суточные закономерности, обусловленные изменением траектории движения солнца, которое определяет освещенность для данного места и времени. Прохождение облаков создает тени, которые вносят стохастическую изменчивость во временные ряды производства, и предсказать их гораздо сложнее. Иными словами, стохастическая составляющая характеризуется значительной изменчивостью, так как зависит от метеорологических условий [21, 82].

Хотя производство электроэнергии на солнечных электростанциях в значительной степени определяется уровнем солнечного излучения, поставщики метеоданных обычно не предоставляют такую информацию. Это связано с трудностями в определении облачности, включая ее высоту и типы облаков. В связи с этим солнечная радиация не может быть принята в качестве исходных переменных при построении модели прогнозирования.

Поскольку солнечная радиация меняется в зависимости от сезона (*month, day, hour*), все эти переменные учитываются в данной задаче. В качестве значимых переменных используются значения соответствующих часов за 3 дня (*gen-i*), поскольку при исключении случайных составляющих имеется общая динамика производства. В дополнение к ним алгоритм также учитывает такие метеорологические факторы, как температура воздуха (*temp*), облачность (*cloudcover*) и осадки (*precipitation*), в качестве случайных компонентов. В таблице 3.5 приведены перечисленные выше исходные и прогнозные данные.

Таблица 3.5 – Выборки исходных данных и прогнозные данные

Число	<i>hour</i>	0:00	01:00	...	23:00
Генерация 2 суток назад	<i>gen-3</i>	X_1	X_2	...	X_{24}
Генерация 1 суток назад	<i>gen-2</i>	X_{25}	X_{26}	...	X_{48}
Генерация текущих суток	<i>gen-1</i>	X_{49}	X_{50}	...	X_{72}
Осадки	<i>precipitation</i>	X_{73}	X_{74}	...	X_{96}
Температура	<i>temp</i>	X_{97}	X_{98}	...	X_{120}
Облачность	<i>cloudcover</i>	X_{121}	X_{122}	...	X_{144}
Номер месяца	<i>month</i>	X'_1			
Номер дня	<i>day</i>	X'_2			
Номер часов	<i>Hour</i>	X'_3			
Прогноз генерации на сутки вперед	<i>gen</i>	Y_1	Y_2	...	Y_{24}

На рисунке 3.7 показана роль этих переменных при построении модели вычисленными алгоритмами.




Рисунок 3.7 - Роль переменных при построении моделей прогнозирования выработки СЭС

Гиперпараметры алгоритмов настраивались так же, как и для ветровых электростанций с помощью функции *GridSearchCV* (библиотеки *sklearn*). Весь набор данных разделен на обучение и тестирование в соотношении 70 к 30. Рисунок 3.8 показывает зависимость оценки модели R^2 от глубины деревьев решений.




Рисунок 3.8 - Зависимость вероятности модели от глубины деревьев

На графике видно, что наилучшее значение глубины деревьев

соответствует моменту, когда оценка на обучающей выборке достигает максимума, а оценка на тестовой выборке начинает стабилизироваться. В таблице 3.6 приведена достоверность моделей, а также показан отрезок процесса тестирования модели на рисунке 3.9.

Таблица 3.6 – Достоверности моделей

		Дархан	Моннар	Бухуг	Сумбэр	Говь	Гэгээн	Ошибка
RF	MAE, МВт	0,32	0,39	0,56	0,27	0,84	0,52	0,48
	nMAE, %	17,75	18,12	17,55	12,45	15,62	18,68	16,69
XG	MAE, МВт	0,19	0,23	0,32	0,16	0,41	0,29	0,26
	nMAE, %	10,72	10,49	9,99	7,43	7,65	10,50	9,46
AD	MAE, МВт	0,17	0,20	0,29	0,14	0,38	0,26	0,24
	nMAE, %	9,48	9,36	9,14	6,26	7,65	9,36	8,54




Рисунок 3.9 - Отрезок процесса тестирования модели

Очевидно, что модель адаптивного бустинга (*AdaBoost*) стала наиболее достоверной, поскольку обладает меньшей погрешностью, чем другие

модели.

3.3.2 Результаты прогнозирования

По разработанной модели адаптивного бустинга спрогнозированы 10 суточных графиков выработки на шести солнечных электростанциях, которые вырабатывают электроэнергию в ЦЭС Монголии. Сопоставление прогнозов и фактических графиков генерации рассмотренных солнечных электростанций показано на рисунке 3.10.




Рисунок 3.10 - Сопоставление прогнозов и фактических графиков генерации солнечных электростанций

В таблицах 3.7, 3.8 также приведены результаты прогнозирования суточных графиков выработки рассматриваемых солнечных электростанций.

Таблица 3.7 – Результаты прогнозирования выработки СЭС № 1–3

	Дархан		Моннар		Бухуг	
	MAE, MBm	nMAE, %	MAE, MBm	nMAE, %	MAE, MBm	nMAE, %
1	0,00	0,00	0,25	12,77	0,07	2,30
2	0,08	4,35	0,08	3,45	0,35	9,04
3	0,21	10,42	0,25	12,24	0,48	13,74
4	0,04	1,75	0,10	3,15	0,12	2,88
5	0,12	5,77	0,42	20,00	0,08	6,67
6	0,08	8,33	0,21	7,69	0,21	10,42
7	0,15	9,13	0,00	0,00	0,25	6,74
8	0,04	1,37	0,29	10,45	0,16	3,84
9	0,29	30,43	0,08	8,00	0,18	5,38
10	0,29	12,73	0,08	2,82	0,58	15,73
Результат	0,13	8,43	0,18	8,06	0,25	7,67

Таблица 3.8 – Результаты прогнозирования выработки СЭС № 4–6

	Сумбэр		Говь		Гэгээн	
	MAE, MBт	nMAE, %	MAE, MBт	nMAE, %	MAE, MBт	nMAE, %
1	0,00	0,00	0,65	21,33	0,08	2,35
2	0,43	29,48	0,28	6,19	0,29	7,78
3	0,00	0,00	0,62	10,95	0,62	25,86
4	0,21	8,62	0,22	2,65	0,25	6,19
5	0,12	5,36	0,12	2,33	0,29	13,73
6	0,04	1,82	0,25	3,09	0,36	10,13
7	0,21	11,90	0,83	13,89	0,16	3,52
8	0,04	1,85	0,21	3,76	0,08	2,63
9	0,08	3,70	0,21	2,66	0,04	1,22
10	0,06	2,27	0,38	5,49	0,12	2,78
Результат	0,12	6,50	0,38	7,23	0,23	7,62

Средняя погрешность по модулю прогнозирования (MAE) составила от 0,12 до 0,25 МВт; нормализованная средняя ошибка по модулю в процентах

($nMAE$) составила от 6,5 до 8,43 %.

Выводы по главе 3

В первой главе представлен краткий обзор использования и ресурсов возобновляемой энергии в Монголии. Очевидно, что в ближайшем будущем источники, вырабатывающие электроэнергию на базе возобновляемых ресурсов, будут играть значительную роль в составе генерирующих объектов. Без методологий краткосрочного прогнозирования генерации этих источников невозможно улучшить планирование режимов работы энергосистемы, его эффективность и точность. В этом и заключается актуальность содержания третьей главы.

В связи с динамическими и стохастическими свойствами изменения энергоносителей возобновляемой энергии возникает потребность в применении искусственного интеллекта, тем более, что ансамблевые методы машинного обучения позволяют определять нелинейную и нестационарную зависимость временного ряда, поскольку позволяют создавать многофакторные модели. Для решения поставленных задач были разработаны ансамблевые модели с использованием алгоритмов случайного леса (RF), адаптивного бустинга (Ada) и экстремального градиентного бустинга (XGB). Результаты экспериментов показали, что модель адаптивного бустинга обладает наилучшей точностью.

Для задачи прогнозирования суточного графика выработки электроэнергии на ветровых электростанциях средняя погрешность по модулю (MAE) составила от 2,42 до 3,48 МВт; нормализованная средняя погрешность по модулю в процентах ($nMAE$) – от 12,3 до 13,3 %, тогда как для солнечных электростанций MAE составила от 0,12 до 0,25 МВт; $nMAE$ – от 6,5 до 8,43 %.

На основе этих экспериментальных результатов предложен алгоритм адаптивного бустинга ($AdaBoost$) в задаче прогнозирования суточного

графика выработки как для ветровых, так и для солнечных электростанций. Впервые применены ансамблевые модели машинного обучения в поставленных задачах.

ГЛАВА 4 ОПТИМИЗАЦИЯ НОРМАЛЬНЫХ РЕЖИМОВ РАБОТЫ ЦЕНТРАЛЬНОЙ ЭНЕРГОСИСТЕМЫ МОНГОЛИИ

В четвертой главе сформулированы задачи оптимизации для Центральной энергосистемы (ЦЭС) Монголии с учетом ее особенностей и свойств. Разработаны алгоритмы для оптимизации нормальных режимов работы электроэнергетической системы за счет распределения активной мощности между теплоэлектроцентралями (ТЭЦ) с учетом возобновляемых источников энергии (ВИЭ), таких как ветровые и солнечные электростанции.

Настоящая глава посвящена применению детерминированных методов, таких как линейное программирование и метода Ньютона-Рафсона, для оптимизации установившихся режимов ЭЭС с учетом критериев минимизации потерь электроэнергии и финансовых расход энергосистемы (на примере ЦЭС Монголии). Реализация алгоритмов оптимизации выполнена с помощью программного пакета *Pandapower* в среде программирования *Python*.

4.1 Решение оптимизационных задач

Задачи оптимизации режимов существенно зависят от масштабов и перспектив. В энергетических задачах большую актуальность приобрела оптимизация установившихся режимов ЭЭС на краткосрочном интервале, в том числе суточное планирование, являющееся одной из основных ролей диспетчерского управления.

В краткосрочной перспективе решается ряд задач, например, выбор оптимального состава генерирующего блока, распределение активной и реактивной мощностей между ними, размещение резервов активной мощности по агрегатам, минимизация потерь электроэнергии и планирование оптимальных энергетических балансов. Методы оптимизации также применяются в регулировании частоты и напряжения ЭЭС [3]. В настоящей

главе невозможно решить все перечисленные задачи, поэтому основное внимание уделено распределению активной мощности между электростанциями, которое является наиболее общим в случае учета конкретных критериев. Выдвигаются научные и инженерные идеи по разработке и совершенствованию методик оптимизации. В качестве примера ниже приведены некоторые исследования в области оптимизации в энергетике.

В работах [141, 142] определено оптимальное соотношение между ТЭЦ и ВИЭ с учетом соответствующих ограничений. В процессе оптимизации режимов ЭЭС применение симплекс-метода дало возможность снизить такие параметры, как потребление топлива, потери электроэнергии в сетях и негативное влияние на экологию, при этом обеспечив экономическую целесообразность.

В работе [90] представлено решение, позволяющее одновременно улучшить финансовое положение энергосистемы штата Джорджия (США) и сократить вредные выбросы от выработки электроэнергии. Для составления оптимального баланса активной и реактивной мощности предлагается метод нелинейного программирования, в том числе метод неопределенных множителей Лагранжа.

В работе [143] также решена задача оптимального покрытия графика нагрузки энергосистемы за счет перераспределения мощности между ТЭЦ. Методом неопределенных множителей Лагранжа определен минимальный расход топлива на ТЭЦ при обеспечении баланса электроэнергии энергосистемы.

Брамм А.М и др. [144] предлагают стохастические методы в задаче оптимизации конфигурации электрической сети и распределения выработки между электростанциями. В результате работы доказано, что генетические алгоритмы могут быть применены для минимизации затрат на покрытие потерь ЭЭС, в которой вся электроэнергия вырабатывается на ВИЭ.

В исследованиях [100, 145] описано применение генетического

алгоритма, в частности, метода роя частиц (*Particle Swarm Optimization, PSO*), для оптимального размещения компенсаторов реактивной мощности в электрической сети. Представленный алгоритм стал более эффективной оптимизационной моделью для решения этой задачи.

В работе [93, 94] была поставлена задача минимизировать расход топлива на выработку как электроэнергии, так и тепла за счет оптимального планирования режимов в системе ТЭЦ. Эта задача была решена с помощью различных стохастических алгоритмов, а именно методов роя частиц и эволюции. На основании полученных результатов можно сделать вывод, что примененные генетические алгоритмы показывают свою эффективность в улучшении технико-экономических показателей ТЭЦ.

Вышеупомянутые исследования позволяют сделать следующие выводы: при рассмотрении поведения простых систем с небольшим количеством признаков, детерминированные методы, такие как градиентный спуск или метод Лагранжа, могут быть эффективными, и их реализация будет простой. В задачах многокритериальной оптимизации в многомерных и сложных системах детерминированные методы неприменимы из-за ряда проблем, включая медленную сходимость, застревание в локальных экстремумах, чувствительность к начальным условиям и необходимость большого объема вычислений [21, 94]. Для работы с высокоразмерными и сложными признаковыми пространствами часто используются стохастические методы и алгоритмы оптимизации. Эти методы могут быть более эффективными в условиях высокой размерности и сложности задач, позволяя находить более качественные решения. В ситуациях с предсказуемыми условиями и отсутствием стохастических факторов применение стохастических методов может быть излишним и усложнять процесс оптимизации. В таких случаях детерминированные методы могут быть более эффективными и обеспечивать надежные результаты. Гибридные модели могут объединить преимущества вышеупомянутых методов для достижения лучших результатов, но их реализация довольно сложна.

4.2 Постановка задачи оптимизации

4.2.1 Особенности исследуемого объекта

В таблице 4.1 представлена информация об источниках электроэнергии ЦЭС Монголии.

Таблица 4.1 – Источники энергии ЦЭС Монголии

	Наименование	Установленная мощность, [МВт]	Цена продажа, [тугрик./кВтч]
1	ТЭЦ – 2	24	102.140
2	ТЭЦ – 3	198	53.860
3	ТЭЦ – 4	772	45.790
4	ТЭЦ – Дархан	83	83.940
5	ТЭЦ – Эрдэнэт	86	100.960
6	ТЭЦ – ГОК	53	102.730
7	ТЭЦ – Даланзадгад	9	200.000
8	КЭС – Ухаахудаг	18	191.440
9	ВЭС – Салхит	50	334.464
10	ВЭС – Цэций	50	330.943
11	ВЭС – Шанд	55	334.464
12	СЭС – Дархан	10	580.911
13	СЭС – Моннар	10	609.076
14	СЭС – Бухуг	15	570.349
15	СЭС – Сумбэр	10	609.076
16	СЭС – Говь	30	499.935
17	СЭС – Гэгээн	15	538.663
18	Импорт	345	384.190

В ЦЭС Монголии осуществляется модель единого покупателя. Как правило, в этой модели существует один субъект, который покупает электроэнергию у ряда генерирующих объектов на основе конкуренции по минимальной цене. Из таблицы 4.1 видно, что себестоимость электроэнергии на ТЭЦ малой мощности выше в 1,2...2,2 раза, чем на ТЭЦ-4, являющейся относительно крупным источником. Цена на импорт из ЕЭС России

уточняется посредством договора между двумя странами, и она зависит от нескольких факторов. По сравнению с внутренними ТЭЦ импортная электроэнергия в (3,7...8,4) раз дороже, что отрицательно влияет на финансовое положение энергосистемы. Кроме того, экспорт электроэнергии ограничивается техническими причинами. Кроме того, в связи с инвестиционными затратами на ВИЭ их цены относительно выше, чем на другие источники. Неопределенность и неожиданные изменения в этих источниках приводят к нарушениям в реализации планируемых режимов работы и функционирования рыночных отношений в ЭЭС.

По расположению источников, три ТЭЦ, одна ветровая электростанция, две солнечные электростанции с установленной мощностью 1069 МВт расположены в Улан-Баторском районе, так что большая часть генерирующих мощностей централизована в одной зоне энергоснабжения и возникает необходимость передачи электроэнергии на большие расстояния. Кроме того, особенностью района Багануур-Чойра является то, что в этом районе электроэнергия вырабатывается только ВИЭ с установленной мощностью 110 МВт. Экспериментально и практически показано, что эти факторы отрицательно влияют на потери в сетях.

В настоящее время планирование суточного графика выработки электроэнергии реализуется по простому алгоритму с использованием *Microsoft Excel*. Принцип существующего алгоритма заключается в покрытии суточного графика нагрузки таким образом, чтобы малые ТЭЦ работали с высокими КПД и полностью обеспечивали нагрузку тепловых сетей соответствующих городов, а ТЭЦ-4 регулировала выработку электроэнергии с учетом ВИЭ. Причем дефицит электроэнергии в ЦЭС покрывается за счет импорта из ЕЭС России, а профицит «утекает обратно» в виде экспорта, особенно в ночное время. Основными ограничениями являются минимальная и максимальная генерация каждой электростанции, а также ограничение импортной мощности. Недостаток этого алгоритма в том, что он не учитывает экономичности, т. е. целевая функция не удовлетворяет

требованиям оптимальности, маломощные ТЭЦ загружаются стабильно, а нагрузка регулируется ТЭЦ-4, имеющей самую низкую себестоимость электроэнергии. Этот алгоритм не позволяет также рассчитать установившийся режим работы ЭЭС.

Указанные выше причины приводят к необходимости искать эффективный способ покрытия суточного графика нагрузки, отвечающего принятым критериям. Таким образом, для ЦЭС Монголии решение задачи оптимального распределения активной мощности между ТЭЦ с учетом ВИЭ становится актуальной.

4.2.2 Математическая формулировка

Цели планирования выработки ТЭЦ на сутки вперед заключается в следующем: минимизация финансовых затрат энергосистемы и потерь мощности в сети при производстве электроэнергии с учётом ограничений. Таким образом, математическая формулировка имеет следующий вид.

Целевые функции: Минимизация средней цены покупки электроэнергии у ТЭЦ.

$$C = \sum_{i=1}^N C_i(P_i) \rightarrow \min ; \quad (4.1)$$

Минимизация потерь мощности в сети.

$$\Delta P = \sum_{i=1}^N L_i(P_i) \rightarrow \min ; \quad (4.2)$$

где N – число электростанций; C_i – цена i -й электростанции; P_i – мощность i -й электростанции; ΔP – потери мощности в сети; L_i – функция потерь в сети.

В случае минимизации финансового расхода единого покупателя в суточном интервале целевая функция определяется следующим выражением.

$$C_{CHP} \sum_{t=1}^{24} P_{CHP_t} + C_{PV} \sum_{t=1}^{24} P_{PV_t} + C_{WP} \sum_{t=1}^{24} P_{WP_t} + C_{imp} \sum_{t=1}^{24} P_{imp_t} \rightarrow \min ; \quad (4.3)$$

При минимизации потерь электроэнергии в суточном интервале целевая функция имеет следующий вид.

$$\sum_{t=1}^{24} L(P_{CHP_t}, P_{PV_t}, P_{WP_t}, P_{imp_t}, P_{load_t}) \rightarrow \min ; \quad (4.4)$$

где C_{CHP} – средняя себестоимость электроэнергии, выработанной на ТЭЦ; P_{CHP_t} – потребляемая мощность от всех ТЭЦ в t -й час; C_{PV} – средняя себестоимость электроэнергии, выработанной на СЭС; P_{PV_t} – потребляемая мощность от СЭС в t -й час; C_{WP} – средняя себестоимость электроэнергии, выработанной на ВЭС; P_{WP_t} – потребляемая мощность от ВЭС в t -й час; C_{imp} – стоимость импортируемой электроэнергии из ЕЭС России; P_{imp_t} – импортируемая мощность в t -й час; P_{load_t} – потребление электроэнергии в t -й час.

Учитывая природные характеристики ВИЭ, генерируемую ими мощность P_{PV} или P_{WP} нельзя рассматривать как зависимые переменные. В отличие от ТЭЦ, их себестоимости C_{PV} и C_{WP} меньше без учета инвестиций. Итак, мощности ТЭЦ P_{CHP} служат зависимыми переменными в задаче.

Критерием конкуренции между источниками является себестоимость вырабатываемой электроэнергии, заданная в начале текущего года. Следует отметить, что себестоимость электроэнергии для каждого источника не изменяется, т. е. имеется линейная зависимость между выработкой электроэнергии и себестоимостью. Таким образом, уравнение связи, определяющее зависимость между независимыми переменными (стоимость электроэнергии электростанций) и зависимыми переменными (мощность электростанций), имеет линейную зависимость. При минимизации потерь мощности в сети уравнение связи характеризуется не линейной, а квадратичной зависимостью. В качестве условий ограничения должны быть

наложены следующие.

По диапазону генерации каждой электростанции:

$$P_{\min i} \leq P_i \leq P_{\max i}; \quad (4.5)$$

где $P_{\min i}$; $P_{\max i}$ – предельные значения мощности i -й ТЭЦ.

По перетокам в сечениях:

$$P_{\min j}^L \leq P_j^L \leq P_{\max j}^L, j = 1 \dots M; \quad (4.6)$$

где $P_{\min j}^L$, $P_{\max j}^L$ – предельные значения перетоков мощности по j -й ВЛ.

По балансу мощности энергосистемы:

$$P_k^{gen} - P_k^{load} = V_k \sum_{k'=1}^K V_{k'} [G_{kk'} \cos(\delta_{kk'}) + B_{kk'} \sin(\delta_{kk'})] ; \quad (4.7)$$

$$Q_k^{gen} - Q_k^{load} = V_k \sum_{k'=1}^K V_{k'} [G_{kk'} \sin(\delta_{kk'}) - B_{kk'} \cos(\delta_{kk'})] ; \quad (4.8)$$

где $k, k' = (1 \dots K)$ – номер узлов; P_k^{gen}, Q_k^{gen} – активная и реактивная мощность на k -ом узле; P_k^{load}, Q_k^{load} – активная и реактивная нагрузка на k -ом узле; $V_k, V_{k'}$ – напряжения узлов k и k' ; $\delta_{kk'}$ – разность фаз напряжений узлов k и k' ; $G_{kk'}, B_{kk'}$ – проводимость и сопротивление ветви между узлами k и k' .

Чтобы линеаризовать и упростить уравнения баланса мощности (4.7, 4.8) можно сделать следующие допущения:

1) Себестоимость электроэнергии ТЭЦ и ее активная мощность не зависят от генерации реактивной мощности. Таким образом, реактивная часть уравнения баланса мощности не учитывается.

2) При линеаризации уравнения баланса активное сопротивление обычно не учитывается, так как оно существенно меньше реактивного. Отсюда, проводимость считается $G_{kk'} = 0$ и уравнение баланса записывается следующим образом:

$$P_k^{gen} - P_k^{load} = V_k \sum_{k'=1}^K V_{k'} B_{kk'} \sin(\delta_{kk'}) ; \quad (4.9)$$

3) Предположим, что напряжения в узлах V_k и $V_{k'}$ равны 1.0 единице, так что влиянием реактивной мощности в сети можно пренебречь. Таким образом, уравнение баланса мощности имеет следующий вид:

$$P_k^{gen} - P_k^{load} = \sum_{k'=1}^K B_{kk'} \sin(\delta_{kk'}) ; \quad (4.10)$$

4) Видно, что уравнение стало значительно проще. Однако уравнение содержит нелинейную составляющую $\sin(\delta_{kk'})$. Если угол $\delta_{kk'}$ мал и выражен в радианах $\sin(\delta_{kk'}) = \delta_{kk'}$, тогда уравнение баланса преобразовывается к следующему виду:

$$P_k^{gen} - P_k^{load} = \sum_{k'=1}^K B_{kk'} (\delta_k - \delta_{k'}) = \sum_{k'=1}^K \frac{(\delta_k - \delta_{k'})}{x_{kk'}} ; \quad (4.11)$$

где $x_{kk'}$ – реактивное сопротивление ветви между узлами k и k' .

$$P_k^{gen} - P_k^{load} = \sum_{k'=1}^K \frac{(\delta_k - \delta_{k'})}{x_{kk'}} = \sum_{k'=1}^K P_{kk'} ; \quad (4.12)$$

где $P_{kk'}$ – переток между узлами k и k' .

После указанных выше допущения уравнение баланса активной мощности для ЦЭС Монголии можно записать следующим образом:

$$\sum_{t=1}^{24} P_{CHPt} + \sum_{t=1}^{24} P_{PVt} + \sum_{t=1}^{24} P_{WPt} \pm \sum_{t=1}^{24} P_{FLOWt} = \sum_{t=1}^{24} P_{LOADt} ; \quad (4.13)$$

где P_{FLOWt} – величина перетока между ЦЭС и ЕЭС России в t -й час; P_{LOADt} – потребление электроэнергии центральной энергосистемы в t -й час.

Для достижения поставленных целей применимы детерминированные методы оптимизации в связи с отсутствием стохастических условий. Метод линейного программирования может быть применен к задаче минимизации средней цены покупки электроэнергии с тепловой электростанции при

условии, что уравнение баланса активной мощности линеаризовано. Отсутствует необходимость в линеаризации уравнения баланса мощности и других ограничений для минимизации потерь в сети, так как будет использоваться метод Ньютона второго порядка.

4.3 Методы решения задачи

4.3.1 Применение линейного программирования

Линейное программирование широко используется в задачах энергетики, более того, этим методом решается ряд задач управления режимами при учете функционирования электроэнергетического рынка. Общий недостаток детерминированных методов заключается в сложности перебора всех возможных решений задачи. С использованием языка программирования *Python* решена проблема перебора решений. Из-за сложности принципа предлагаемого алгоритма применительно к реальной энергосистеме рассмотрим его применение в упрощенной сети с тремя узлами, которая показана на рисунке 4.1.




Рисунок 4.1 - Исходная схема для расчета

Для сети, рассматриваемой в качестве примера, предположим, что ветви между узлами имеют одинаковые реактивные сопротивления и длины. Предположим также, что максимальный допустимый переток по каждой ветви равен 260 МВт, максимальная мощность электростанции А равна 390 МВт, а электростанции Б – 150 МВт. Стоимость производства

электроэнергии на электростанции А составляет 45 туг./кВтч, а на электростанции Б – 53 туг./кВтч. Потребление электроэнергии составляет 450 МВт. При экономичном распределении мощности такая сеть выглядит так, как показано на рисунке 4.2.




Рисунок 4.2 - Режим работы сети при экономичном распределении перетоков

Видно, что по критерию экономической диспетчеризации электростанция А загружается полностью, так как у неё цена на производство электроэнергии ниже чем на электростанции Б. Остальное потребление покрывается электростанцией Б. В этом случае цена на производство электроэнергии рассчитывается следующим образом:

$$\text{Цена} = 390 \text{ МВт} \cdot 45 \frac{\text{тыс.тугрик}}{\text{МВт}} \text{ ч} + 60 \text{ МВт} \cdot 53 \frac{\text{тыс.тугрик}}{\text{МВт}} \text{ ч} = 20\,730 \text{ тыс. тугрик} \quad (4.14)$$

На рисунке 4.2 видно, что переток на ветви между узлами 1 и 3 не допускается, так как он превышает значение $P_{\text{МДП}}$ на 20 МВт. Для уменьшения перетока в данном сечении, необходимо перераспределить мощность между электростанциями А и Б. Именно в этой части алгоритма реализуются технические критерии. На рисунке 4.3 показан режим после перераспределения мощности.




Рисунок 4.3 - Режим работы энергосистемы после оптимизации

После перераспределения мощности режим работы сети удовлетворяет как экономическим, так и техническим критериям, несмотря на рост цены, который составляет 480 тыс. тугриков.

$$\text{Цена}_1 = 330 \text{ МВт} \cdot 45 \frac{\text{тыс. тугрик}}{\text{МВт}} \text{ ч} + 120 \text{ МВт} \cdot 53 \frac{\text{тыс. тугрик}}{\text{МВт}} \text{ ч} = 21\,210 \text{ тыс. тугрик} \quad (4.15)$$

В реальном случае экономическая часть этого алгоритма реализует критерий минимума суммарных затрат. Сначала алгоритм назначает всем ТЭЦ минимальное значение мощности, т. е. они загружаются по минимальной мощности. В случае, если выработка энергосистемы не полностью покрывает потребление, алгоритм загружает ТЭЦ, отпускающую энергию по самой низкой цене, до максимального возможного значения либо до значения, соответствующего потреблению. После того как эта ТЭЦ полностью загружена, при наличии потребности загружается следующая ТЭЦ. Далее они загружаются до полного обеспечения баланса мощности. Если мощности ТЭЦ оказывается недостаточно, то остальное потребление покрывается за счет импорта из ЕЭС России.

В случае профицита электроэнергии в связи со случайной загрузкой ВИЭ и отключением крупных потребителей алгоритм сначала разгружает ТЭЦ, отпускающей электроэнергию по максимальной цене, до технического минимума. При загрузке всех ТЭЦ по минимальной мощности избыточная электроэнергия выдаётся в сторону ЕЭС, то есть осуществляется экспорт. В технической части оптимизации реализуются ограничения по перетокам ВЛ. В случае нарушения установленных ограничений осуществляется перераспределение выработки электроэнергии между ТЭЦ.

4.3.2 Применение метода Ньютона

В энергетических системах метод Ньютона используется для оптимизации распределения активной и реактивной мощностей, что

помогает минимизировать потери и улучшить эффективность работы системы. Метод Ньютона второго порядка является мощным инструментом, который может быть применен как для нахождения экстремумов функций, так и для решения систем нелинейных уравнений.

В случае, если этот метод применяется для решения задач минимизации потерь в сетях, необходимо сначала определить функцию потерь мощности (4.4) и ее производные по переменным. Затем, начальное приближение выбирается в соответствии с требованиями задачи. Далее, метод Ньютона второго порядка применяется для отыскания значения минимума функции потерь мощности. Этот итерационный процесс повторяется до тех пор, пока не будет достигнута заданная точность или выполнено заданное предельное количество итераций. Алгоритм предлагаемого метода реализуется следующими шагами.

1. задание начального приближения x_0 для искомого корня уравнения;
2. вычисление значения функции $f(x)$ и ее производной $f'(x)$ в точке x_0 ;
3. вычисление значения второй производной $f''(x)$ в точке x_0 ;
4. вычисление следующего приближения x_1 для искомого корня уравнения по формуле:

$$x_1 = x_0 - \left(\frac{f'(x_0)}{f''(x_0)} \right) \quad (4.16)$$

5. повторение шагов 2-4 до достижения необходимой точности или выполнения заданного числа итераций.

Метод Ньютона рекомендуется использовать в случае, если задача минимизации достаточно хорошо локализована. Другими словами, если имеется несколько локальных минимумов, то метод Ньютона второго порядка не может быть использован. В этом случае более целесообразным является применение стохастических методов. Однако при применении метода Ньютона второго порядка к задачам минимизации потерь мощности могут возникнуть некоторые ограничения и проблемы. Например, особые точки или разрывы в функции потерь мощности могут привести к

неустойчивости метода или отсутствию его сходимости. Этот метод также может быть вычислительно затратным для больших сетей или сложных моделей, требуя значительного количества вычислительных ресурсов. Несмотря на эти ограничения метод Ньютона второго порядка является мощным и эффективным численным методом для нахождения корней уравнений и оптимизации функций. Он широко применяется при решении подобных задач. На рисунке 4.4 показана структурная схема алгоритма метода Ньютона второго порядка.




Рисунок 4.4 - Структурная схема алгоритма метода Ньютона второго порядка

Метод Ньютона также применяется для анализа устойчивости и нормальных режимов работы ЭЭС, что позволяет оценивать влияние различных факторов на работу сети. В данном случае нужно установить начальные значения параметров сети, таких как узлы и ветви. После этого запускается алгоритм для решения системы уравнений, который позволяет

интерактивно корректировать значения параметров до достижения желаемого устойчивого состояния ЭЭС.

4.4 Результаты оптимизации нормальных режимов работы

Оптимизация установившихся режимов работы ЭЭС за счет перераспределения активной мощности между ТЭЦ проводилась по двум подходам. Первый подход сосредоточен на снижение потерь в сети с применением метода Ньютона, а второй – на уменьшение финансовых затрат ЭЭС с использованием метода линейного программирования.

Расчеты выполнены на базе библиотеки *Pandapower*, предоставляющей функции для моделирования, анализа и оптимизации электрических сетей с использованием языка программирования *Python*. *Pandapower* позволяет рассчитать нормальный режим работы электроэнергетической системы, определяя такие параметры, как напряжения, перетоки в сечениях и потери в сети. Программный пакет *Pandapower* также позволяет реализовывать алгоритмы оптимизации, включая метод Ньютона второго порядка и линейное программирование. Эти алгоритмы могут быть реализованы с использованием функций оптимизации из библиотеки *scipy*.

Поставленные задачи оптимизации невыполнимы без моделей суточных графиков нагрузки как ЭЭС, так и ее узлов, а также графиков производства электроэнергии ВИЭ. Во второй и третьей главах было установлено, что для получения этих графиков можно применять ансамблевые модели машинного обучения.

С помощью ранговых моделей [114, 115, 118] также моделированы суточные графики нагрузки каждого узла. Так, можно определить рабочую зону, в которой обеспечивается выработка электроэнергии на ТЭЦ, как показано на рисунке 4.5.




Рисунок 4.5 - Суточный график нагрузки и выработки энергосистемы на 25.12.2021

Поскольку энергопотребление в энергосистеме и генерация ВИЭ считаются нерегулируемыми переменными, распределение активной мощности должно осуществляться в указанном диапазоне. Иными словами, роль зависимых переменных должна выполнять генерация ТЭЦ. Следует отметить, что реализация алгоритмов выполнена с использованием языка программирования *Python*.

4.4.1 Расчет установившегося режима

На рисунке 4.6 представляется структурная схема ЦЭС на напряжениях 35 кВ, 110 кВ и 220 кВ. Подстанция Селендума, которая находится на территории России, выбрана в качестве балансирующего узла. С использованием программного средства *RastrWin* и языка программирования *Python* проведен анализ установившегося режима ЦЭС Монголии. При расчете режимов были использованы фактические параметры оборудования, представленные по узлам и ветвям в ПРИЛОЖЕНИИ А.




Рисунок 4.6 - Структура ЦЭС

Эксперимент был проведен на 282 точках, и это означает, что расчет нормального режима осуществлялся на 12 почасовых графиках нагрузки, случайно отобранных из каждого месяца. На рисунке 4.7 показано распределение активной мощности между ТЭЦ в соответствии с действующим алгоритмом.




Рисунок 4.7 - Временной ряд генерации источников центральной энергосистемы по базовому сценарию

На рисунке 4.8 представлен график потерь мощности рассматриваемого временного ряда. Речь идет о базовой версии без оптимизации.




Рисунок 4.8 - График потерь мощности ЦЭС при работе по базовому сценарию

Результаты, полученные с использованием двух различных подходов (программного комплекса *Rastrwin* и инструмента *Pandapower*) совпадают. Это подтверждает, что язык программирования *Python* может быть успешно использован для решения поставленных задач. Следовательно, библиотека *Pandapower* подходит для оптимального распределения активной мощности между ТЭЦ, так как она предлагает эффективные методы оптимизации.

4.4.2 Распределение активной мощности

В данном разделе представлены результаты сравнительного анализа

планирования генерации на теплоэлектроцентрали (ТЭЦ) для различных сценариев: без применения оптимизации, с акцентом на снижение потерь в электрической сети и с целью уменьшения средней стоимости покупки электроэнергии у ТЭЦ.

Первым сценарием является критерие минимизации потерь в сети. Целевая функция состоит в минимизации потерь мощности в сети. Таким образом, различия в ценах на ТЭЦ и импортную электроэнергию не учитываются и устанавливаются в одинаковом размере. Расчет проведен для реальной схемы, представленной на рисунке 4.6, а также использованы реальные параметры оборудования, приведенные в ПРИЛОЖЕНИИ А.

Второй сценарий предполагает минимизацию финансовых затрат на ЭЭС. Вследствие линеаризации уравнения баланса мощности перераспределение активной мощности осуществлялось по отдельности. Перераспределение активной мощности выполнено на упрощенной схеме ЦЭС Монголии, представленной на рисунке 4.9. Затем выполнен расчет нормального режима работы ЭЭС в реальных условиях.




Рисунок 4.9 - Упрощенная схема ЦЭС Монголии

Исходные данные по источникам и ветвям между узлами приведены в таблицах 4.2 и 4.3.

Таблица 4.2 – Данные электростанций и импорта из ЕЭС России

Название	P_{MAX} , [МВт]	P_{MIN} , [МВт]	Цена, [туг./кВтч]	Цена, [о.е]
ТЭЦ-2	22	18	102.14	0.82
ТЭЦ-3	176	168	53.86	0.43
ТЭЦ-4	740	500	45.79	0.36
ТЭЦ-Дархан	62	60	83.94	0.66
ТЭЦ-Эрдэнэт	60	58	100.96	0.81
ТЭЦ-ГОК	42	40	102.73	0.82
Импорт	-	-	384.19	3.07

Таблица 4.3 – Данные ВЛ между узлами

Начальный узел	Конечный узел	Активное сопротивление, R , [ом]	Реактивное сопротивление, X , [ом]	Проводимость, B , [мкСм]	Длина, [км]
0	2	18.650	82.060	-521.5	194.8
1	2	14.690	100.76	-410.7	153.0
1	3	18.810	106.64	-706.5	257.7
2	3	19.140	84.190	-535.1	195.3
3	4	2.820	12.420	-78.9	118.3
4	5	19.890	67.64	-487.7	178.0
5	1	23.720	95.19	-625.1	250.1

Сравнительные результаты расчетов установившихся режимов для вышеуказанных сценариев представлены в таблице 4.4. В случае без оптимизации потери электроэнергии в сети составила 3,12 % от общего электропотребления, затем данный показатель снизился до 3,05 % за счет перераспределения мощности по критерию минимизации потерь в сети. Однако, средняя цена продаж на оптовом рынке увеличилась на 0,08 о.е. или 9,9 туг./ кВтч. Оптимизация по критерию минимизации затраты снизила среднюю цену продажи электроэнергии с 0,51 до 0,49 о.е.. Средние потери электроэнергии в сети также снизились на 0,02 %. На рисунке 4.10 также показаны графики технико-экономических показателей ЦЭС Монголии.

Таблица 4.4 – Итоговые результаты оптимизации распределения мощности между источниками

	Без оптимизации		По критерию минимальных потерь		По критерию минимальных затрат	
	Потери, [%]	Средняя цена, [о.е]	Потери, [%]	Средняя цена, [о.е]	Потери, [%]	Средняя цена, [о.е]
1	2.77	0.47	2.69	0,54	2.76	0.48
2	2.92	0.44	2.75	0,53	2.92	0.43
3	3.33	0.46	3.18	0,56	3.32	0.45
4	3.59	0.47	3.43	0,60	3.59	0.47
5	3.61	0.57	3.50	0,68	3.60	0.56
6	3.41	0.54	3.33	0,64	3.39	0.53
7	2.63	0.56	2.56	0,61	2.62	0.54
8	3.11	0.49	3.02	0,59	3.11	0.48
9	2.83	0.50	2.69	0,61	2.83	0.50
10	3.03	0.53	2.93	0,60	3.02	0.51
11	3.06	0.53	2.90	0,57	3.02	0.49
12	3.12	0.56	3.06	0,58	3.09	0.54
Результат	3.12	0.51	3.05	0.59	3.10	0.49




Рисунок 4.10 - График среднесуточных потерь мощности и цены покупки у ТЭЦ

Графики, представленные на рисунке 4.10 показывают, что среднесуточные потери мощности в сети уменьшаются после перераспределения по данному критерию. Однако, перераспределение генерируемой электроэнергии с акцентом на минимизацию потерь может негативно сказаться на финансовых показателях ЭЭС. Во втором сценарии наблюдается снижение средней цены закупки электроэнергии у ТЭЦ по сравнению с первым вариантом, однако значительного изменения в потерях мощности в сети не произошло.

Очевидно, что любой из предложенных алгоритмов может быть применён к оптимизации нормальных режимов работы ЦЭС Монголии путём перераспределения активной мощности между ТЭЦ по соответствующим критериям. Например, рассмотрим один из суточных графиков генерации. На рисунке 4.11 показан график распределения мощности между источниками без оптимизации, выполненный по действующей методике на практике.




Рисунок 4.11 - Планирование суточной генерации источников без оптимизации

Как видно из рис. 4.11, целесообразно, чтобы малые ТЭЦ вырабатывали постоянную мощность, а нагрузка энергосистемы регулируется ТЭЦ-4 с учетом генерации ВИЭ. Полупиковые и пиковые части графика нагрузки покрываются за счет импорта из ЕЭС России. На рисунке 4.12 представлены результаты перераспределения мощности между источниками после оптимизации по заданным критериям.




Рисунок 4.12 - Планирование суточной генерации источников по различным критериям

Выводы по главе 4

Рассмотрение принципов распределения активной мощности между источниками ЦЭС Монголии. Показало, что наиболее актуально – внедрение программных средств для оптимального планирования режимов работы. Поэтому поставленной целью является разработка алгоритма оптимизации нормальных режимов работы ЦЭС Монголии путем планирования графиков генерации ТЭЦ с учетом генерации ВИЭ.

Для достижения поставленной цели были решены задачи, направленные на снижение потерь мощности в электрической сети и уменьшение финансовых расходов на оптовом рынке электроэнергии. Применялись детерминированные подходы к оптимизации, такие как линейное программирование и метод Ньютона второго порядка, поскольку рассматриваемая система не имеет стохастических характеристик. Реализация алгоритмов была выполнена с использованием библиотеки *Pandapower* на языке *Python*.

В ходе экспериментов, проведенных на 12 суточных графиках, были получены следующие результаты. Без применения оптимизации потери электроэнергии составили 3,12 % от общего объема электропотребления, а средняя цена закупки электроэнергии у ТЭЦ составила 0,51 о.е., что эквивалентно 63,3 туг./кВтч. После проведения оптимизации с целью минимизации потерь в сети этот показатель снизился до 3,05 % от общего потребления, что означает уменьшение потерь на 0,07 п.п. или 2,24 %. При оптимизации с акцентом на снижение затрат средняя цена закупки у ТЭЦ составила 0,49 о.е. (60,8 туг./кВтч), что соответствует снижению на 3,92 %. Таким образом, предложенные алгоритмы могут эффективно использоваться для оптимизации распределения активной мощности между ТЭЦ в соответствии с заданными критериями и обеспечивают реальную экономию.

ЗАКЛЮЧЕНИЕ

В диссертационной работе рассмотрена задача планирования режимов работы ЭЭС. В публикациях и исследованиях, посвященных решению задач планирования режимов работы ЭЭС, достаточно подчеркивается актуальность решаемой задачи. Из литературы видно, что суть планирования режимов работы заключается в принятии оптимальных решений, основанных на предсказаниях развития процессов, происходящих в энергосистеме. В соответствии с этим, в диссертационной работе рассмотрены подходы к проблемам прогнозирования и оптимизации процессов, происходящих в энергосистеме.

Проведен анализ методов и подходов, используемых в задаче прогнозирования временных рядов и оптимизации режимов работы электроэнергетической системы. Установлено, что не существует единого универсального метода или подхода к решению задач, полностью удовлетворяющего всем требованиям и не имеющего недостатков, поскольку каждый метод обладает своими особенностями. Сделан вывод, что для получения достаточно точной модели необходимо провести эксперименты с использованием различных методов как классических, так и математического моделирования с использованием ЭВМ.

Разработаны методики краткосрочного прогнозирования электропотребления применительно к ЦЭС Монголии, основанные на использовании таких методов, как линейная регрессия, авторегрессия и ансамблевые модели машинного обучения. Экспериментально показано, что среди разработанных методик высокой точностью обладают ансамблевые модели, в том числе алгоритм экстремального градиентного бустинга (*XGBoost*), обеспечивший снижение погрешности до 1,25 %. Использование многофакторной модели позволило снизить погрешность классических методов с 2,26 до 1,25 %. Таким образом, снижение ошибки составило 1,01 п.п, или 44,7 %. На основе прогноза суточного графика нагрузки

энергосистемы с помощью ранговых моделей выполняется прогнозирование нагрузки в узлах с погрешностью не более 2,0 %.

В связи со стохастическими и хаотическими характеристиками энергоносителей возобновляемой энергии применять монотонные методы в задаче краткосрочного прогнозирования генерации не рекомендуется. Доказано, что ансамблевые модели машинного обучения могут одновременно учитывать несколько факторов, влияющих на временной ряд. Именно в этом заключается обоснованность использования ансамблевых моделей в задаче прогнозирования генерации ВИЭ. Величина средней погрешности прогноза для ветровых электростанций составляет от 12,3 до 13,3 %, а для солнечных – от 6,5 до 8,43 %.

Поставлена задача оптимизации установившихся режимов ЭЭС за счет перераспределения активной мощности между ТЭЦ с учетом генерации ВИЭ (на примере ЦЭС Монголии). Определен рабочий диапазон ТЭЦ в суточном графике с помощью моделей электропотребления и выработки электроэнергии ВИЭ, построенных ансамблевыми моделями машинного обучения. Для решения задачи минимизации финансовых затрат ЭЭС использован метод линейного программирования, а для минимизации потерь электроэнергии – метод Ньютона второго порядка. С помощью этих математических методов экспериментально показано, что предлагаемые алгоритмы могут быть применены к поставленной задаче оптимизации по соответствующим критериям.

Реализация и эксперименты алгоритмов, примененных в задачах прогнозирования, оптимизации и расчета нормальных режимов ЭЭС проведены для реальной схемы и элементов ЦЭС Монголии. Эти алгоритмы также впервые протестированы и применены к ЦЭС Монголии с помощью программного средства *Pandapower* и языка программирования *Python*. По результатам диссертационного исследования можно сделать следующие выводы.

Во-первых, ЦЭС Монголии, как и современная ЭЭС, является сложным

объектом, состоящим из множества структурных составляющих, взаимосвязанных иерархически, а также имеет характерную часть генерации от ВИЭ. В связи с растущей интеграцией ВИЭ нестабильность баланса активной мощности ЭЭС увеличивается, поскольку появляется дополнительная неопределенность при планировании режима, в частности, при планировании на сутки вперед. Таким образом, существует необходимость в новом подходе к краткосрочному планированию режимов работы ЭЭС, основанном на использовании искусственного интеллекта, с возможностью учета стохастических и хаотических факторов.

Во-вторых, установлено, что в задаче краткосрочного прогнозирования применение ансамблевых моделей является более эффективным, поскольку эти модели позволяют учитывать как внутренние, так и внешние факторы, влияющие на любые временные ряды. На базе библиотеки *Pandapower*, разработаны также алгоритмы оптимизации нормальных режимов ЭЭС на основе интеллектуализации процесса управления генерацией ЭЭС. Предлагаемые алгоритмы реализованы на языке программирования *Python*, что позволило создавать единые наборы программных средств, обеспечивающих сбор информации о состоянии контролируемой энергосистемы, представление информации оперативному персоналу и формирование рекомендаций по коррекции текущего режима работы энергосистемы.

По итогам исследований в диссертационной работе предложена концепция системы предиктивной аналитики режимов работы электроэнергетической системы с возобновляемыми источниками.

СПИСОК ЛИТЕРАТУРЫ

1. Methodological Framework for Planning the Development of Mongolia's Electric Power Systems and Energy Industry / Bat-Erdene B. и др. // Energy Systems Research. 2023. Т. 6. №. 4. С. 5-24. Doi: 10.25729/esr.2023.04.0001.
2. Оптимизация режимов электростанций и энергосистем: учебник / Т. А. Филиппова, Ю. М. Сидоркин, А. Г. Русина. – 2-е изд. – Новосибирск: Изд-во НГТУ, 2016. С. 15.
3. Режимы электрических станций и электроэнергетических систем: учебное пособие / А.Г. Русина, Т.А. Филиппова. – Новосибирск: изд-во НГТУ. 2016. – 400 с. (Серия Учебники НГТУ)
4. Информационное обеспечение при разработке системы управления режимами работы энергосистем / Степанов В. М. и др. // Известия Тульского государственного университета. Технические науки. 2021. №. 12. С. 3-7. Doi: 10.24412/2071-6168-2021-12-3-8
5. Устойчивость интеллектуальной энергосистемы и методы интеллектуального управления / Воропай Н. И. и др. // Методические вопросы исследования надежности больших систем энергетики. 2019. С. 147-156.
6. Баринов В. А., Мамиконянц Л. Г., Строев В. А. Развитие математических моделей и методов для решения задач управления режимами работы и развития энергосистем // Электричество. 2005. №. 7. С. 8-21.
7. Theoretical Analysis of Integrated Community Energy Systems (ICES) Considering Integrated Demand Response (IDR): A Review of the System Modelling and Optimization / Kong D. и др. // Energies. 2023. Т. 16. №. 10. С. 4129. Doi: 10.3390/en16104129.
8. Prospects and Challenges of the Machine Learning and Data-Driven Methods for the Predictive Analysis of Power Systems: A Review /

- Strielkowski W. и.др. // *Energies*. 2023. Т. 16. №. 10. С. 4025. Doi: 10.3390/en16104025.
9. Alimi O. A., Ouahada K., Abu-Mahfouz A. M. A review of machine learning approaches to power system security and stability // *IEEE Access*. 2020. Т. 8. С. 113512-113531. Doi: 10.1109/ACCESS.2020.3003568.
 10. Machine learning and deep learning in energy systems: A review / Forootan M. M. и.др. // *Sustainability*. 2022. Т. 14. №. 8. С. 4832. Doi: 10.3390/su14084832.
 11. Review on deep learning applications in frequency analysis and control of modern power system / Zhang Y. и.др. // *International Journal of Electrical Power & Energy Systems*. 2022. Т. 136. С. 107744. Doi: 10.1016/j.ijepes.2021.107744.
 12. A review on artificial intelligence for grid stability assessment / You S. и.др. // 2020 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm). IEEE, 2020. С. 1-6. Doi: 10.1109/SmartGridComm47815.2020.9302990.
 13. Kim I., Kim B., Sidorov D. Machine Learning for Energy Systems Optimization // *Energies*. 2022. №. 11. Т. 15. С. 4116. Doi: 10.3390/en15114116.
 14. Лыгин М. М., Корнилов Г. П., Кожевников И. О. Анализ современных методов оптимизации // *Энергетические и электротехнические системы*. 2019. С. 4-11. <https://elibrary.ru/item.asp?id=41745938>.
 15. Optimization of a solar-based integrated energy system considering interaction between generation, network, and demand side / Luo X. и.др // *Applied Energy*. 2021. Т. 294. С. 116931. Doi: 10.1016/j.apenergy.2021.116931.
 16. Niu M., Wan C., Xu Z. A review on applications of heuristic optimization algorithms for optimal power flow in modern power systems // *Journal of Modern Power Systems and Clean Energy*. 2014. №. 4. Т. 2. С. 289-297. Doi: 10.1007/s40565-014-0089-4.

17. Uncertainty models for stochastic optimization in renewable energy applications / Zakaria A. и др // Renewable Energy. 2020. Т. 145. С. 1543-1571. Doi: 10.1016/j.renene.2019.07.081.
18. Longo S., Montana F., Sanseverino E. R. A review on optimization and cost-optimal methodologies in low-energy buildings design and environmental considerations // Sustainable cities and society. 2019. Т. 45. С. 87-104. Doi: 10.1016/j.scs.2018.11.027.
19. Обзор метаэвристических методов оптимизации, применяемых при решении электроэнергетических задач / Алехин Р. А. и др. // Вестник Самарского государственного технического университета. Серия: Технические науки. 2019. №. 3. Т. 63. С. 6-19.
20. Rural electrification: An overview of optimization methods / Akbas B. и др // Renewable and Sustainable Energy Reviews. 2022. Т. 156. С. 111935. Doi: 10.1016/j.rser.2021.111935.
21. Thirunavukkarasu M., Sawle Y., Lala H. A comprehensive review on optimization of hybrid renewable energy systems using various optimization techniques // Renewable and Sustainable Energy Reviews. 2023. Т. 176. С. 113192. Doi: 10.1016/j.rser.2023.113192.
22. A review on the integrated optimization techniques and machine learning approaches for modeling, prediction, and decision making on integrated energy systems / Alabi T. M. и др // Renewable Energy. 2022. Т. 194. С. 822-849. Doi: 10.1016/j.renene.2022.05.123.
23. Сулейманов К. А. Мониторинг и управление индикаторами энергетической безопасности на основе синхрофазорных измерений в режиме реального времени // SOCAR Proceedings. 2022. №. 2. С. 100-104. Doi: 10.5510/OGP20220200682.
24. Neis P., Wehrmeister M. A., Mendes M. F. Model driven software engineering of power systems applications: literature review and trends // IEEE Access. 2019. Т. 7. С. 177761-177773. Doi: 10.1109/ACCESS.2019.2958275.

25. Автоматизированные системы диспетчерского управления в электросетевом комплексе / Барова В. А. И и.др. // Горное оборудование и электромеханика. 2018. № 4(138). С. 46-52. Doi: 10.26730/1816-4528-2018-4-46-52.
26. Update on current approaches, challenges, and prospects of modeling and simulation in renewable and sustainable energy systems / Yoro K. O. и.др. // Renewable and Sustainable Energy Reviews. 2021. Т. 150. С. 111506. Doi: 10.1016/j.rser.2021.111506.
27. Bagchi S., Rastogi R. K. An overview of Distribution Automation in TATA Power DDL and its effective contribution for power sector reform in North and North West Delhi // 2019 International Conference on Electrical, Electronics and Computer Engineering (UPCON). IEEE. 2019. С. 1-6. Doi: 10.1109/UPCON47278.2019.8980268.
28. Mishra S., Glaws A., Palanisamy P. Predictive Analytics in Future Power Systems: A Panorama and State-Of-The-Art of Deep Learning Applications // Optimization, Learning, and Control for Interdependent Complex Networks. 2020. С. 147-182.
29. Ibrahim M. S., Dong W., Yang Q. Machine learning driven smart electric power systems: Current trends and new perspectives // Applied Energy. 2020. Т. 272. С. 115237. Doi: 10.1016/j.apenergy.2020.115237.
30. Мозохин А. Е., Шведенко В. Н. Анализ направлений развития цифровизации отечественных и зарубежных энергетических систем // Научно-технический вестник информационных технологий, механики и оптики. 2019. Т. 19. №. 4. С. 657-672. Doi: 10.17586/2226-1494-2019-19-4-657-672.
31. Khuntia S. R., Rueda J. L., van Der Meijden M. A. M. M. Forecasting the load of electrical power systems in mid-and long-term horizons: a review // IET Generation, Transmission & Distribution. 2016. Т. 10. №. 16. С. 3971-3977.
32. Батейкин Д. В. Современные аспекты развития теории и практики

- прогнозирования социально-экономического развития регионов // Новая наука: современное состояние и пути развития. 2016. №. 1(1). С. 59-63.
33. Alfares H. K., Nazeeruddin M. Electric load forecasting: literature survey and classification of methods // International journal of systems science. 2002. №. 1. Т. 33. С. 23-34. Doi: 10.1080/00207720110067421.
 34. An overview of energy demand forecasting methods published in 2005–2015 / Ghalekhondabi I. и др // Energy Systems. 2017. №. 2. С. 411-447. Doi: 10.1007/s12667-016-0203-y.
 35. Методы прогнозирования электропотребления в распределительных сетях (обзор) / Абдурахманов А. М. и др // Электротехника: сетевой электронный научный журнал. 2016. №. 1. Т. 3. С. 3-23.
 36. Patel H, Shah M. Energy Consumption and Price Forecasting Through Data-Driven Analysis Methods: A Review // SN Computer Science. 2021. №. 4. Т. 2. С. 1-16. Doi: 10.1007/s42979-021-00698-2.
 37. Tawn R., Browell J. A review of very short-term wind and solar power forecasting // Renewable and Sustainable Energy Reviews. 2022. Т. 153. С. 111758. Doi: 10.1016/j.rser.2021.111758.
 38. A comprehensive review of hybrid models for solar radiation forecasting / Guermoui M. и др // Journal of Cleaner Production. 2020. Т. 258. С. 120357. Doi: 10.1016/j.jclepro.2020.120357.
 39. Prediction of solar power generation based on random forest regressor model / Khalyasmaa A. и др // 2019 International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON). IEEE. 2019. С. 0780-0785. Doi: 10.1109/SIBIRCON48586.2019.8958063.
 40. A weather-based hybrid method for 1-day ahead hourly forecasting of PV power output / Yang H. Т. и др // IEEE transactions on sustainable energy. 2014. №. 3. Т. 5. С. 917-926. Doi: 10.1109/TSTE.2014.2313600.
 41. Gupta P., Singh R. PV power forecasting based on data-driven models: a review // International Journal of Sustainable Engineering. 2021. №. 6. Т.

14. C. 1733-1755. Doi: 10.1080/19397038.2021.1986590.
42. Zhao L, Muhammad S.N., Hafiz M.J., Ahmed N.A. A review on proliferation of artificial intelligence in wind energy forecasting and instrumentation management // Environmental Science and Pollution Research. 2022. №. 29. T. 29. C. 43690-43709. Doi: 10.1007/s11356-022-19902-8.
43. Manusov V., Matrenin P., Nazarov M., Beryozkina S. Short-Term Prediction of the Wind Speed Based on a Learning Process Control Algorithm in Isolated Power Systems // Sustainability. 2023. №. 2. T. 15. C. 1730. Doi: 10.3390/su15021730.
44. Tiwari S. Wind speed forecasting methods for wind energy generation // 2022 1st International Conference on Informatics (ICI). IEEE. 2022. C. 143-147. Doi: 10.1109/ICI53355.2022.9786880.
45. Weather forecasting for renewable energy system: a review / Meenal R. и др // Archives of Computational Methods in Engineering. 2022. №. 5. T. 29. C. 2875-2891. Doi: 10.1007/s11831-021-09695-3.
46. Филиппова Т. А, Русина А. Г, Дронова Ю. В. Модели и методы прогнозирования электроэнергии и мощности при управлении режимами электроэнергетических систем: монография. Новосибирск: изд-во НГТУ, 2009. С. 87-90
47. Electrical energy consumption forecast using support vector machines / Vinagre E. и др // 27th International Workshop on Database and Expert Systems Applications (DEXA). IEEE. 2016. C. 171-175. Doi: 10.1109/DEXA.2016.046.
48. Visser L., AlSkaif T., Van Sark W. Operational day-ahead solar power forecasting for aggregated PV systems with a varying spatial distribution // Renewable Energy. 2022. T. 183. C. 267-282. Doi: 10.1016/j.renene.2021.10.102.
49. Zhang Y., Li R. Short term wind energy prediction model based on data decomposition and optimized LSSVM // Sustainable Energy Technologies

- and Assessments. 2022. T. 52. C. 102025. Doi: 10.1016/j.seta.2022.102025
50. Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series / Sadaei H. J. и.др // Energy. 2019. T. 175. C. 365-377. Doi: 10.1016/j.energy.2019.03.081.
 51. Regression model for predicting the speed of wind flows for energy needs based on fuzzy logic / Khasanzoda N. и.др // Renewable Energy. 2022. T. 191. C. 723-731. Doi: 10.1016/j.renene.2022.04.017.
 52. A hybrid neuro-fuzzy power prediction system for wind energy generation / Saleh A. E. и.др // International Journal of Electrical Power & Energy Systems. 2016. T. 74. C. 384-395. Doi: 10.1016/j.ijepes.2015.07.039.
 53. Electric load analysis and forecasting using artificial neural networks / Fernandes K. C. и.др // 3rd International Conference on Trends in Electronics and Informatics (ICOEI). IEEE. 2019. C. 1274-1278. Doi: 10.1109/ICOEI.2019.8862695.
 54. Антоненков Д. В., Матренин П. В. Исследование ансамблевых и нейросетевых методов машинного обучения в задаче краткосрочного прогнозирования электропотребления горных предприятий // Электротехнические системы и комплексы. 2021. №. 3 (52). С. 57-65. Doi: 10.18503/2311-8318-2021-3(52)-57-65.
 55. A survey of artificial neural network in wind energy systems / Marugán A. P. и.др // Applied energy. 2018. T. 228. C. 1822-1836. Doi: 10.1016/j.apenergy.2018.07.084.
 56. Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing / Theocharides S. и.др // Applied Energy. 2020. T. 268. C. 115023. Doi: 10.1016/j.apenergy.2020.115023.
 57. Alobaidi M.H. Robust ensemble learning framework for day-ahead forecasting of household based energy consumption // Applied energy. 2018. T. 212. C. 997-1012. Doi: 10.1016/j.apenergy.2017.12.054.
 58. A hybrid regression model for day-ahead energy price forecasting / D.

- Bissing и.др // IEEE Access. 2019. Т. 7. С. 36833-36842. Doi: 10.1109/ACCESS.2019.2904432.
59. Load forecasting using autoregressive integrated moving average and artificial neural network / L. C. P. Velasco и.др // Int. J. Adv. Comput. Sci. Appl. 2018. №. 7. Т. 9. С. 23-29.
 60. Forecasting electricity consumption using ARIMA model / F. Mahia и.др // 2019 International Conference on Sustainable Technologies for Industry 4.0 (STI). IEEE. 2019. С. 1-6. Doi: 10.1109/STI47673.2019.9068076.
 61. Hour-ahead wind power forecast based on random forests / C. Nichiforov и.др // Renewable energy. 2017. Т. 109. С. 529-541. Doi: 10.1016/j.renene.2017.03.064.
 62. Robust and automatic data cleansing method for short-term load forecasting of distribution feeders / N. Huygheus-Beaufond и.др // Applied energy. 2020. Т. 261. С. 114405. Doi: 10.1016/j.apenergy.2019.114405.
 63. Kotikov E.S., Samsonova E.S., Rusina A.G., Filimonov V.A. Load predictive modeling in power system nodes in the experimental software package // Electric power. Transmission and distribution. 2019. № 1(52). С. 60-65. [online], Available: <https://www.elibrary.ru/item.asp?id=37238016>.
 64. Hayes B. P., Gruber J. K., Prodanovic M. Multi-nodal short-term energy forecasting using smart meter data // IET Generation, Transmission & Distribution. 2018. №. 12. Т. 12. С. 2988-2994. Doi:10.1049/iet-gtd.2017.1599.
 65. Multi-node load forecasting based on multi-task learning with modal feature extraction / M. Tan и.др // Engineering Applications of Artificial Intelligence. 2022. Т. 112. С. 104856. Doi: 10.1016/j.engappai.2022.104856.
 66. Multinodal forecasting of industrial power load using participation factor and ensemble learning / M. Tan и.др // 2020 IEEE 4th Conference on Energy Internet and Energy System Integration (EI2). IEEE. 2020. С. 745-750. Doi: 10.1109/EI250167.2020.9346689.

67. Multinodal load forecasting for distribution systems using a fuzzy-artmap neural network / T. Abreu и.др // Applied Soft Computing. 2018. Т. 71. С. 307-316. Doi: 10.1016/j.asoc.2018.06.039.
68. Rai S., De M. Effect of Load Contribution Factor on Multinodal Load Forecasting // IEEE EUROCON 2021-19th International Conference on Smart Technologies. IEEE. 2021. С. 455-459. Doi: 10.1109/EUROCON52738.2021.9535644.
69. A new formulation of multinodal short-term load forecasting based on adaptive resonance theory with reverse training / A.J. Amorim и.др // Electric Power Systems Research. 2020. Т. 179. С. 106096. Doi: 10.1016/j.epsr.2019.106096.
70. Multinodal load forecast using euclidean ARTMAP Neural network / A.B.A. Ferreira и.др // 2019 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America). IEEE. 2019. С. 1-6. Doi: 10.1109/ISGT-LA.2019.8895411.
71. Stephen B., Telford R., Galloway S. Non-Gaussian residual based short term load forecast adjustment for distribution feeders // IEEE Access. 2020. Т. 8. С. 10731-10741. Doi: 10.1109/ACCESS.2020.2965320.
72. Incorporating practice theory in sub-profile models for short term aggregated residential load forecasting / B. Stephen и.др // IEEE Transactions on Smart Grid. 2015. №. 4. Т. 8. С. 1591-1598. Doi: 10.1109/TSG.2015.2493205.
73. Machine learning and deep learning in energy systems: A review / Forootan M. M. и.др. // Sustainability. 2022. Т. 14. №. 8. С. 4832. Doi: 10.3390/su14084832.
74. A trend fixed on firstly and seasonal adjustment model combined with the ε -SVR for short-term forecasting of electricity demand / J. Wang J и.др // Energy Policy. 2009. №. 11. Т. 37. С. 4901-4909. Doi: 10.1016/j.enpol.2009.06.046.
75. Çevik H. H., Çunkaş M. Short-term load forecasting using fuzzy logic and

- ANFIS // Neural Computing and Applications, 2015, №. 6. Т. 26. С. 1355-1367. Doi: 10.1007/s00521-014-1809-46
76. Модель организации данных и процесса обучения нейронной сети при построении графиков нагрузки на сутки вперед / Н.И. Калантаевская и.др // Алматинского университета энергетики и связи. 2019. Т. 3. С. 11. Doi: 10.51775/1999-9801_2019_46_3_11.
77. Lahouar A., Slama J. B. H. Hour-ahead wind power forecast based on random forests // Renewable energy. 2017. Т. 109. С. 529-541. Doi: 10.1016/j.renene.2017.03.064.
78. Breiman L. Random forests // Machine learning. 2001. Т. 45. С. 5-32. doi: 10.1023/a:1010933404324.
79. Hybrid short-term load forecasting scheme using random forest and multilayer perceptron / J. Moon и.др // Energies. 2018. №. 12. Т. 11. С. 3283. Doi: 10.3390/en11123283.
80. Jorgensen K. L., Shaker H. R. Wind power forecasting using machine learning: State of the art, trends and challenges // 2020 IEEE 8th International Conference on Smart Energy Grid Engineering (SEGE). IEEE. 2020. С. 44-50. Doi: 10.1109/SEGE49949.2020.9181870.
81. Freund Y., Schapire R. E. A decision-theoretic generalization of on-line learning and an application to boosting // Journal of computer and system sciences. 1997. №. 1. Т. 55. С. 119-139. Doi: 10.1006/jcss.1997.1504.
82. Phan Q. T., Wu Y. K., Phan Q. D. A hybrid wind power forecasting model with XGBoost, data preprocessing considering different NWP's // Applied Sciences. 2021. №. 3. Т. 11. С. 1100. Doi: 10.3390/app11031100.
83. Сидорова А. В., Черемных А. А., Русина А. Г. Python как инструмент оптимизации режима ГЭС в составе ЭЭС // Вестник Казанского государственного энергетического университета. 2021. №. 2. Т. 13. С. 119-132. <https://elibrary.ru/item.asp?id=46626446>.
84. Теория и методы оптимизации: учеб. Пособие для академического бакалавриата / Е.А. Кочегурова.: изд-во Юрайт, 2016. 113 С. Серия:

Университеты России.

85. Optimal management of energy consumption in an autonomous power system considering alternative energy sources / Manusov V. и.др // Mathematics. 2022. №. 3. Т. 10. С. 525. Doi: 10.3390/math10030525.
86. Альсова О. К., Артамонова А. В. Многокритериальная модель планирования водно-энергетических режимов Новосибирской ГЭС // Известия Самарского научного центра Российской академии наук. 2017. №. 6(1). Т. 19. С. 112-117.
87. Барахтенко Е. А., Войтов О. Н. Подход к краткосрочной оптимизации функционирования интегрированной энергетической системы // Методические вопросы исследования надежности больших систем энергетики. 2021. С. 162-171. <https://elibrary.ru/item.asp?id=47261546>.
88. Real-time optimal power flow using twin delayed deep deterministic policy gradient algorithm / Woo J. H. и.др // IEEE Access. 2020. Т. 8. С. 213611-213618. Doi: 10.1109/ACCESS.2020.3041007.
89. Бербенец С. В., Сошникова К. Д. Математические методы оптимизации режимов энергосистемы // Инновационные подходы в решении научных проблем. 2020. С. 64-69. <https://elibrary.ru/item.asp?id=42934639>.
90. Jo H., Park J., Kim I. Environmentally constrained optimal dispatch method for combined cooling, heating, and power systems using two-stage optimization // Energies. 2021. №. 14. Т. 14. С. 4135. Doi: 10.3390/en14144135.
91. Unit commitment model in smart grid environment considering carbon emissions trading / Zhang N. и.др // IEEE transactions on smart grid. 2015. №. 1. Т. 7. С. 420-427.
92. Energy storage in power system operation: The power nodes modeling framework / Heussen K. и.др // 2010 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT Europe). IEEE. 2010. С. 1-8.
93. Nazari-Heris M., Mohammadi-Ivatloo B., Gharehpetian G. B. A

- comprehensive review of heuristic optimization algorithms for optimal combined heat and power dispatch from economic and environmental perspectives // *Renewable and Sustainable Energy Reviews*. 2018. Т. 81. С. 2128-2143. Doi: 10.1016/j.rser.2017.06.024.
94. Оптимизация распределения потоков мощности в энергосистеме с помощью генетических алгоритмов / Поляхов Н. Д. и др // *Современные проблемы науки и образования*. 2012. №. 3. С. 170-170. <https://elibrary.ru/item.asp?id=17822410>.
 95. Park J., Jo H., Kim I. The selection of the most cost-efficient distributed generation type for a combined cooling heat and power system used for metropolitan residential customers // *Energies*. 2021. №. 18. Т. 14. С. 5606. Doi: 10.3390/en14185606.
 96. Lambora A., Gupta K., Chopra K. Genetic algorithm-A literature review // 2019 international conference on machine learning, big data, cloud and parallel computing (COMITCon). IEEE. 2019. С. 380-384.
 97. Клер А. М., Корнеева З. Р., Елсуков П. Ю. Оптимизация режимов энергосистем, включающих ТЭЦ и ГЭС, с использованием дерева сочетаний условий функционирования // *Вестник Иркутского государственного технического университета*. 2010. №. 7 (47). С. 170-175.
 98. Sulaiman M. H., Mustaffa Z. Solving optimal power flow problem with stochastic wind–solar–small hydro power using barnacles mating optimizer // *Control Engineering Practice*. 2021. Т. 106. С. 104672. Doi: 10.1016/j.conengprac.2020.104672.
 99. Manusov V. Z., Matrenin P. V., Khasanzoda N. Swarm algorithms in dynamic optimization problem of reactive power compensation units control // *International Journal of Electrical & Computer Engineering* (2088-8708). 2019. №. 5. Т. 9. С. 3967-3974. Doi: 10.11591/ijece.v9i5.pp3967-3974.
 100. Манусов В. З., Матренин П. В., Третьякова Е. С. Оптимизация размещения источников реактивной мощности с помощью алгоритма

- роя частиц с генетической адаптацией // Промышленная энергетика. 2016. №. 8. С. 34-40. <https://elibrary.ru/item.asp?id=26717444>.
101. Matrenin P. V., Osgonbaatar T., Sergeev N. N. Overview of Renewable Energy Sources in Mongolia // 2022 IEEE International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON). IEEE. 2022. С. 700-703. Doi: 10.1109/SIBIRCON56155.2022.10016986.
 102. Energy Regulation Commission of Mongolia. Statistic on Energy Performance of the Mongolian Energy System. 2022. available online: <http://www.erc.gov.mn>
 103. N. I. Voropai, B. G. Saneev, S. Batkhuyag and Kh. Enkhjargal. Energy cooperation between Mongolia and Russia: current state and strategic directions [Energeticheskoe Sotrudnichestvo Mongolii i Rossii: Sovremennoe Sostojanie i Strategicheskie Napravlenija] // Spatial economics ["Prostranstvennaia Ekonomika"] (in Russian). 2013. Т. 3. С. 108-122. Doi: 10.14530/se.2013.3.108-122.
 104. Hydrogen production possibility using Mongolian renewable energy/ Dorjgotov A. и.др //IOP Conference Series: Earth and Environmental Science. IOP Publishing. 2019. Т. 291. №. 1. С. 012029. Doi: 10.1088/1755-1315/291/1/012029.
 105. ГЭС: Искусство управления: Монография / Т.А. Филиппова и.др. Новосибирск: Изд-во НГТУ, 2019. 226 с.
 106. Влияние метеофакторов на режимы потребления электроэнергии энергосистем / Макоклюев Б. И. и.др //Методические вопросы исследования надежности больших систем энергетики. 2015. №. 65. С. 405-414.
 107. Модели прогнозирования потребления электроэнергии с учетом влияния метеофакторов / Токарева Г.Р. и.др // Вестник Астраханского государственного технического университета. Серия: Управление, вычислительная техника и информатика. 2018. №. 4. С. 99-106. Doi: 10.24143/2072-9502-2018-4-99-106.

108. Гофман А. В., Ведерников А. С., Шелушенина О. Н. Применение скользящего смещения средней температуры при прогнозировании электропотребления // Вестник Самарского государственного технического университета. Серия: Технические науки. 2021. №. 1. Т. 33. С. 114-118.
109. Бородин А. А. Краткосрочное прогнозирование энергопотребления с учетом метеофакторов // Электроэнергетика глазами молодежи. сб. науч. тр. Томский политехнический университет. Томск: Изд-во ТПУ. 2014. Т. 2. С. 244-247.
110. Хомутов С. О., Серебряков Н. А. Влияние метеорологических факторов на режим потребления электроэнергии группы точек поставки электроэнергии сельскохозяйственных товаропроизводителей // Вестник Алтайского государственного аграрного университета. 2019. №. 5. Т. 175. С. 148-153.
111. Серебряков Н. А. Анализ факторов, влияющих на совокупное электропотребление гарантирующего поставщика // Вестник Иркутского государственного технического университета. 2020. Т. 24. №. 2 (151). С. 366-381. Doi: 10.21285/1814-3520-2020-2-366-381.
112. Прогнозирование суточного графика электропотребления рабочих дней с учетом метеофакторов для центральной энергосистемы Монголии / А.Г. Русина и.др // Известия высших учебных заведений. ПРОБЛЕМЫ ЭНЕРГЕТИКИ. 2022. №. 2. Т. 24. С. 98-107. Doi: 10.30724/1998-9903-2022-24-2-97-106.
113. Rusina A. G., Osgonbaatar T., Matrenin P. V. Short-term Load Forecasting Using Statistical Methods for the Central Power System of Mongolia // 2022 IEEE International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON). IEEE. 2022. С. 2030-2035. Doi: 10.1109/SIBIRCON56155.2022.10017047.
114. A rank analysis and ensemble machine learning model for load forecasting in the nodes of the central Mongolian power system / T. Osgonbaatar, P.

- Matrenin, I. Zicmane, A. Rusina и др. // Inventions. 2023. Vol. 8. iss. 5. Art. 114 (20 p.). Doi: 10.3390/inventions8050114.
115. Ранговый анализ и ансамблевая модель машинного обучения для прогнозирования нагрузок в узлах центральной энергосистемы Монголии = Rank analysis and ensemble machine learning model for forecasting the daily energy load in the central power system of Mongolia / А. Г. Русина, Т. Осгонбаатар, П. В. Матренин. – Текст: непосредственный // Электроэнергия. Передача и распределение. 2023. № 3 (78). С. 36–44.
 116. The IEEE reliability test system: A proposed 2019 update / С. Barrows и др // IEEE Transactions on Power Systems. 2019. №. 1. Т. 35. С. 119-127. Doi: 10.1109/TPWRS.2019.2925557.
 117. Saranchimeg S., Nair N. K. C. A novel framework for integration analysis of large-scale photovoltaic plants into weak grids // Applied Energy. 2021. Т. 282. С. 116141. Doi: 10.1016/j.apenergy.2020.116141.
 118. Осгонбаатар Т. Ранговые модели прогнозирования нагрузки в узлах электроэнергетической системы / Т. Осгонбаатар ; науч. рук. А. Г. Русина. - Текст : непосредственный // Наука. Технологии. Инновации : сб. науч. тр. 16 Всерос. науч. конф. молодых ученых, Новосибирск : Изд-во НГТУ, 2022. Ч. 4. С. 163–166.
 119. Olaofe Z. O. A 5-day wind speed and power forecasts using a layer recurrent neural network (LRNN) // Sustainable Energy Technologies and Assessments, 2014. Т. 6. С.1-24. Doi: 10.1016/j.seta.2013.12.001.
 120. Santos M., González M. Factors that influence the performance of wind farms // Renewable Energy. 2019. Т. 135. С. 643-651. Doi: 10.1016/j.renene.2018.12.033.
 121. Ouyang T., Kusiak A., He Y. Predictive model of yaw error in a wind turbine // Energy. 2017. Т. 123. С. 119-130. Doi: 10.1016/j.energy.2017.01.150.
 122. A new wind power prediction method based on chaotic theory and Bernstein

- Neural Network / Wang C. и др. // Energy. 2016. Т. 117. С. 259-271. Doi: 10.1016/j.energy.2016.10.041.
123. Li X., Sabas J. F., Mendéz V. D. Wind energy forecasting using multiple ARIMA models // 2022 IEEE 18th International Conference on Automation Science and Engineering (CASE). IEEE. 2022. С. 2034-2039. **Doi:** 10.1109/CASE49997.2022.9926516.
 124. Analysis of ARMA solar forecasting models using ground measurements and satellite images / Marchesoni-Acland F. и др // 2019 IEEE 46th Photovoltaic Specialists Conference (PVSC). IEEE. 2019. С. 2445-2451. doi: 10.1109/PVSC40753.2019.8980821.
 125. Forecasting photovoltaic power generation with a stacking ensemble model / Abdellatif A. и др // Sustainability. 2022. №. 17. Т. 14. С. 11083. Doi: 10.3390/su141711083.
 126. Day-ahead solar power plant forecasting accuracy improvement on the hourly basis / Snegirev D. A. и др // 2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus). IEEE. 2019. С. 1088-1091. Doi: 10.1109/EIConRus.2019.8657024.
 127. Agoua X. G., Girard R., Kariniotakis G. Short-term spatio-temporal forecasting of photovoltaic power production // IEEE Transactions on Sustainable Energy. 2017. №. 2. Т. 9. С. 538-546. Doi: 10.1109/TSTE.2017.2747765.
 128. Kim E. G., Akhtar M. S., Yang O. B. Designing solar power generation output forecasting methods using time series algorithms // Electric Power Systems Research. 2023. Т. 216. С. 109073. Doi: 10.1016/j.epsr.2022.109073.
 129. A novel non-iterative correction method for short-term photovoltaic power forecasting / Yin W. и др // Renewable Energy. 2020. Т. 159. С. 23-32. Doi: 10.1016/j.renene.2020.05.134.
 130. Sharadga H., Hajimirza S., Balog R. S. Time series forecasting of solar power generation for large-scale photovoltaic plants // Renewable Energy.

2020. T. 150. C. 797-807. Doi: 10.1016/j.renene.2019.12.131.
131. Forecasting power output of photovoltaic systems based on weather classification and support vector machines / Shi J. и.др // IEEE Transactions on Industry Applications. 2012. №. 3. Т. 48. С. 1064-1069. Doi: 10.1109/TIA.2012.2190816.
 132. Prediction of solar power generation based on random forest regressor model / Khalyasmaa A. и.др // 2019 International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON). IEEE. 2019. С.780-785. Doi: 10.1109/SIBIRCON48586.2019.8958063.
 133. Visser L., AlSkaif T., Van Sark W. Benchmark analysis of day-ahead solar power forecasting techniques using weather predictions // 2019 IEEE 46th Photovoltaic Specialists Conference (PVSC). IEEE. 2019. С. 2111-2116. Doi: 10.1109/PVSC40753.2019.8980899.
 134. Buhan S., Özkazanç Y., Çadırcı I. Wind pattern recognition and reference wind mast data correlations with NWP for improved wind-electric power forecasts // IEEE Transactions on Industrial Informatics. 2016. №. 3. Т. 12. С. 991-1004. Doi: 10.1109/TII.2016.2543004.
 135. Negative correlation learning-based RELM ensemble model integrated with OVMD for multi-step ahead wind speed forecasting / Peng T. и.др // Renewable Energy. 2020. Т. 156. С. 804-819. Doi: 10.1016/j.renene.2020.03.168.
 136. Smart wind speed forecasting approach using various boosting algorithms, big multi-step forecasting strategy / Li Y. и.др // Renewable energy. 2019. Т. 135. С. 540-553. Doi: 10.1016/j.renene.2018.12.035.
 137. Wang L., Guo Y., Li X. Wind speed prediction using measurements from neighboring locations and combining the extreme learning machine and the AdaBoost algorithm // Energy Reports. 2022. Т. 8. С. 1508-1518. Doi: 10.1016/j.egyr.2021.12.062.
 138. Dosdoğru A. T., İpek A. B. Hybrid boosting algorithms and artificial neural network for wind speed prediction //International Journal of Hydrogen

- Energy. 2022. №. 3. Т. 47. С. 1449-1460. Doi: 10.1016/j.ijepes.2021.107365.
139. A multi-level model for hybrid short term wind forecasting based on SVM, wavelet transform and feature selection / Abedinia O. и др. // 2022 IEEE International Conference on Environment and Electrical Engineering and 2022 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe). IEEE. 2022. С. 1-6. Doi: 10.1109/EEEIC/ICPSEurope54979.2022.9854519.
 140. Ouyang T., Kusiak A., He Y. Modeling wind-turbine power curve: A data partitioning and mining approach // Renewable Energy. 2017. Т. 102. С. 1-8. Doi: 10.1016/j.renene.2016.10.032.
 141. Application of the linear programming method in the construction of a mathematical model of optimization distributed energy / Rabe M. и.др // Energies. 2022. №. 5. Т. 15. С. 1872. Doi: 10.3390/en15051872.
 142. Gbadamosi S. L., Nwulu N. I. Optimal power dispatch and reliability analysis of hybrid CHP-PV-wind systems in farming applications // Sustainability. 2020. №. 19. Т. 12. С. 8199. Doi: 10.3390/su12198199.
 143. Реймов К. М., Танирбергенов Р. М. Об оптимальном покрытии графика нагрузки энергосистем в программе Matlab // Молодой ученый. 2017. №. 11. С. 99-102. <https://elibrary.ru/item.asp?id=28840606>.
 144. Оптимизация топологии сети с ВИЭ-генерацией на основе модифицированного адаптированного генетического алгоритма / Брамм А. М. и.др // Энергетика. Известия высших учебных заведений и энергетических объединений СНГ. 2022. №. 4. Т. 65. С. 341-354. Doi: 10.21122/1029-7448-2022-65-4-341-354.
 145. Optimization of power distribution networks in megacities / Manusov V. Z. и.др // IOP Conference Series: Earth and Environmental Science. IOP Publishing. 2017. №. 1. Т. 72. С. 012019. Doi: 10.1088/1755-1315/72/1/012019.

ПРИЛОЖЕНИЕ «А» Параметры, используемые при расчете

Таблица А.1 – Модель подстанций

№	Наименование подстанции	Уровень напряжения, кВ	Расчетное название
1	Селендума	220	s1
2	Дархан	220	t1
3		110	t2
4		35	t3
5	ЗРУ Дархан ТЭЦ	110	t4
6	Шарынгол	110	t5
7	Зуунхараа	110	t6
8	Борнуур	110	t7
9	Эрдэнэт	220	h1
10		110	h2
11		35	h3
12	Булган	110	h4
13	Мурун	110	h5
14	Хархорин	110	h6
15	Цэцэрлэг	110	h7
16	Арвайхээр	110	h8
17	Баянхонгор	110	h9
18	Баянчандмань	110	u1
19	ОРУ ТЭЦ-4	220	u2
20		110	u3
21	ОРУ ТЭЦ-3	110	u4
22	ОРУ ТЭЦ-3	35	u5
23	ОРУ ТЭЦ-2	35	u6
24	Умнуд	110	u7
25	Туул	110	u8

Продолжение таблицы А.1

26	Амгалан	110	u9
27	Улаанбаатар	220	u10
28		110	u11
29	Улаанхуаран	110	u12
30	Дорнод-2	110	u13
31	Умард	110	u14
32	Шонхор	110	u15
33	Баруун	110	u16
34	Сэлбэ	110	u17
35	Телевиз	110	u18
36	Найрамдал	110	u19
37	Налайх	110	u20
38	Илчбаян	110	u21
39	Хушигт	110	u22
40	Зайсан	110	u23
41	Сонгино	220	u24
42		110	u29
43		35	u30
44	Багануур	220	b1
45		110	b2
46		35	b3
47	Чойр	220	b4
48		110	b5
49		35	b6
50	Бор-Ундур	110	b7
51	Ундурхаан	110	b8
52	Баруун-Урт	110	b9
53	Айраг	110	b10

Продолжение таблицы А.1

54	Сайншанд	110	b11
55		35	b12
56	Замын-Ууд	110	b13
57	Мандал	220	g1
58		110	g2
59		35	g3
60	Тавантолгой	220	g4
61		110	g5
62		35	g6
63	Даланзадгад	110	g7
64		35	g8
65	Оюутолгой	220	g9
66		110	g10
67		35	g11
68	Цагаансуврага	220	g12
69		35	g13

Таблица А.2 – Модель воздушных линий электропередач.

№	Начальный узел	Конечный узел	Длина, км	Тип пороводов
1	Улаанбаатар	Багануур	118.3	305-AL1/39-ST1A 220.0
2	Багануур	Чойр	178.0	243-AL1/39-ST1A 220.0
3	Чойр	Бор-Ундур	90.5	122-AL1/20-ST1A 110.0
4	Бор-Ундур	Ундурхаан	181.8	122-AL1/20-ST1A 110.0
5	Ундурхаан	Баруун-Урт	214.5	122-AL1/20-ST1A 110.0
6	Чойр	Айраг	99.1	149-AL1/20-ST1A 110.0
7	Айраг	Сайншанд	124.3	122-AL1/20-ST1A 110.0
8	Сайншанд	Замын-Ууд	193.6	122-AL1/20-ST1A 110.0
9	Чойр	Мандал	178.0	305-AL1/39-ST1A 220.0

Продолжение таблицы А.2

10	Мандал	ОРУ ТЭЦ-4	181.0	305-AL1/39-ST1A 220.0
11	Мандал	Тавантолгой	249.8	305-AL1/39-ST1A 220.0
12	Тавантолгой	Даланзадгад	87.0	122-AL1/20-ST1A 110.0
13	Тавантолгой	Оюутолгой	136.2	305-AL1/39-ST1A 220.0
14	Оюутолгой	Цагаансуврага	159.4	305-AL1/39-ST1A 220.0
15	Селендума	Дархан	194.8	305-AL1/39-ST1A 220.0
16	Дархан	ЗРУ Дархан ТЭЦ	8.3	122-AL1/20-ST1A 110.0
17	ЗРУ Дархан ТЭЦ	Шарынгол	45.0	122-AL1/20-ST1A 110.0
18	Шарынгол	Зуунхараа	71.0	122-AL1/20-ST1A 110.0
19	Зуунхараа	Борнуур	54.4	122-AL1/20-ST1A 110.0
20	Борнуур	Баянчандмань	27.0	122-AL1/20-ST1A 110.0
21	Дархан	Эрдэнэт	153.0	305-AL1/39-ST1A 220.0
22	Эрдэнэт	Булган	54.5	149-AL1/20-ST1A 110.0
23	Булган	Мурун	292.0	122-AL1/20-ST1A 110.0
24	Булган	Хархорин	203.8	149-AL1/20-ST1A 110.0
25	Хархорин	Цэцэрлэг	117.1	122-AL1/20-ST1A 110.0
26	Хархорин	Арвайхээр	125.0	122-AL1/20-ST1A 110.0
27	Арвайхээр	Баянхонгор	205.5	122-AL1/20-ST1A 110.0
28	Мурун	Тэлмэн	278.7	122-AL1/20-ST1A 110.0
29	Дархан	ОРУ ТЭЦ-4	195.3	305-AL1/39-ST1A 220.0
30	Баянчандмань	ОРУ ТЭЦ-4	63.7	122-AL1/20-ST1A 110.0
31	ОРУ ТЭЦ-4	ОРУ ТЭЦ-3	5.5	243-AL1/39-ST1A 110.0
32	ОРУ ТЭЦ-3	ОРУ ТЭЦ-2	3.3	94-AL1/15-ST1A 35.0
33	ОРУ ТЭЦ-3	Умнуд	4.8	243-AL1/39-ST1A 110.0
34	Умнуд	Туул	5.2	243-AL1/39-ST1A 110.0
35	Туул	Улаанбаатар	6.7	243-AL1/39-ST1A 110.0
36	ОРУ ТЭЦ-4	Улаанбаатар	29.4	305-AL1/39-ST1A 220.0
37	Улаанбаатар	Улаанхуаран	1.0	305-AL1/39-ST1A 110.0

Продолжение таблицы А.2

38	Улаанхуаран	Дорнод-2	10.7	305-AL1/39-ST1A 110.0
39	Дорнод-2	Шонхор	10.7	305-AL1/39-ST1A 110.0
40	Шонхор	ОРУ ТЭЦ-4	10.7	305-AL1/39-ST1A 110.0
41	Улаанбаатар	Сэлбэ	14.9	243-AL1/39-ST1A 110.0
42	Сэлбэ	Телевиз	8.4	243-AL1/39-ST1A 110.0
43	Телевиз	Найрамдал	19.2	243-AL1/39-ST1A 110.0
44	Улаанбаатар	Налайх	75.0	122-AL1/39-ST1A 110.0
45	Налайх	Илчбаян	25.0	243-AL1/39-ST1A 110.0
46	Илчбаян	Хушигт	34.7	243-AL1/39-ST1A 110.0
47	Хушигт	Сонгино	37.7	122-AL1/39-ST1A 110.0
48	ОРУ ТЭЦ-4	Сонгино	29.5	243-AL1/39-ST1A 220.0
49	Сонгино	Эрдэнэт	257.7	305-AL1/39-ST1A 220.0

Таблица А.3 - Модель трансформаторов и автотрансформаторов.

№	Наименование подстанции	Марк трансформаторов	Мощность трансформаторов, МВА	Количество
1	Улаанбаатар	АТДЦТН-125000/220/110	125/125/63	2
2	Багануур	АТДЦТН-63000/220/110	63/63/32	2
3	Чойр	OSFPSZ-200000/220	200/200/80	2
4	ОРУ ТЭЦ-4	OSFPSZ9-125000/220	125/125/37.5	2
5	ОРУ ТЭЦ-3	SFSZ11-40000/115	40/40/40	2
6	Эрдэнэт	OSFPSZ9-200000-230	200/200/80	2
7	Сонгино	OSFPSZ11-125000/220	125/125/62.5	2
8	Дархан	АТДЦТН-63000/220/110	63/63/32	2
9	Мандал	OSFPSZ-63000/220	63/63/32	2
10	Тавантолгой	OSFPSZ-125000/220	125/125/62.5	2
11	Оюутолгой	OSFPSZ-125000/220	125/125/62.5	2
12	Сайншанд	ТДТН-16000/110	16/16/16	2

ПРИЛОЖЕНИЕ «Б» Акты о внедрении результатов



NATIONAL DISPATCHING CENTER OF POWER SYSTEM, MONGOLIA

17032 Chingis avenue, 3-rd khoroo,
Han-Uul district, Ulaanbaatar, MONGOLIA
Tel: (976) 70041315, Fax: (976) 7004-3467
E-mail: ndc@ndc.energy.mn

Date 2024. 04. 03

Ref. _____

АКТ

о внедрении результатов кандидатской диссертационной работы
Осгонбаатара Тувшина

Настоящий акт составлен о том, что результаты диссертационной работы на соискание ученой степени кандидата технических наук, выполненной Осгонбаатаром Тувшиным, могут быть реализованы при составлении краткосрочного планирования, в том числе суточного планирования режимов работы Центральной энергосистемы Монголии. Применение предложенной концепции системы предиктивной аналитики режимов работы электроэнергетической системы создаст условие более эффективного и рационального использования возобновляемых источников энергии, что является базовым обеспечением повышения технико-экономических показателей данной энергосистемы.

Подтверждаю, что диссертационная работа на тему «Разработка системы предиктивной аналитики режимов работы электроэнергетической системы с большой долей возобновляемых источников (на примере энергосистемы Монголии)» обладает актуальностью и представляет практический интерес для Центральной энергосистемы Монголии.

ГЛАВНЫЙ ДИСПЕТЧЕР  БААТАР





**СЭРГЭЭГДЭХ ЭРЧИМ ХҮЧ
ҮЙЛДВЭРЛЭГЧДИЙН ХОЛБОО**

Улаанбаатар хот, Чингэлтэй дүүрэг,
5-р хороо, Ялалт Плаза, 14 давхар, 1405 тоот.
Утас: 7700 3010, 8004 4850, 8808 4850
И-мэйл: secretary@mria.mn
Шуудангийн хайрцаг: 13344 Улаанбаатар,
Шуудангийн салбар 51, Ш/Х 443
Вэб: www.mria.mn

2024.04.01 № 01/043
танай _____ -ын № _____

АКТ

о внедрении результатов кандидатской диссертационной работы
Осгонбаатара Тувшина

Настоящим актом подтверждаются, что в ассоциации производителей возобновляемой энергии Монголии обсуждена реализация моделей краткосрочного прогнозирования генерации возобновляемых источников энергии на основе ансамблевых моделей машинного обучения, разработанных в рамках диссертационной работы на тему «Разработка системы предиктивной аналитики режимов работы электроэнергетической системы с большой долей возобновляемых источников (на примере энергосистемы Монголии)».

По результатам совещания рассмотрена актуальность представленных моделей Осгонбаатаром Тувшиным и предложено к внедрению в деятельность присоединенных организаций, вырабатывающих возобновляемую энергию в Центральной энергосистеме Монголии.

Главный директор:



/Т. Хулан/



MRIA
Монголын сэргээгдэх эрчим хүч
үйлдвэрлэгчдийн холбоо



“HYDRO ENGINEERING” LLC

UB Tower Plus, Room number #805, Manlaibaatar Damdinsuren
street, 25th khoroo, 13th khoroolol, Bayanzurkh district,
Ulaanbaatar city, MONGOLIA

Phone number: +976-77127575

Mobile number: +976-99106768

Mail address: info.hydroengineering@gmail.com

Date: 02 April, 2024

To:

Subject:

АКТ

о внедрении результатов диссертационной работы на соискание ученой степени кандидата технических наук Осгонбаатара Тувшина на тему «Разработка системы предиктивной аналитики режимов работы электроэнергетической системы с большой долей возобновляемых источников энергии»

Настоящий акт подтверждается, что программные продукты на основе машинного обучения, разработанные в рамках договора № HE-2023/11 от 1 ноября 2023 г. о выполнении научно-исследовательской работы и отраженные в результатах диссертационной работы Осгонбаатара Тувшина, использованы при формировании отчета по теме «Технические рекомендации по внедрению гидроаккумулирующих электростанций в Центральную энергосистему Монголии» по заказу Министерства энергетики Монголии.

Главный директор:



/Б. Болдбаатар/