

Федеральное государственное бюджетное учреждение науки
Институт систем энергетики им. Л.А. Мелентьева
Сибирского отделения Российской академии наук



На правах рукописи

Домышев Александр Владимирович

**ОПТИМИЗАЦИЯ НОРМАЛЬНЫХ ЭЛЕКТРИЧЕСКИХ РЕЖИМОВ
ЭЛЕКТРОЭНЕРГЕТИЧЕСКИХ СИСТЕМ ПРИ ОПЕРАТИВНОМ И
АВТОМАТИЧЕСКОМ УПРАВЛЕНИИ**

Специальность 05.14.02 – Электрические станции и электроэнергетические
системы

Диссертация

на соискание ученой степени
кандидата технических наук

Научный руководитель:

чл.-корр. РАН, доктор технических наук,
профессор
Воропай Николай Иванович

Иркутск 2020

СОДЕРЖАНИЕ

Список используемых сокращений	5
Введение	7
ГЛАВА 1. Обзор методов оптимального управления электрическими режимами и применения методов обучения для управления энергосистемами	16
1.1 Современные тенденции в развитии энергосистем	16
1.2 Постановка задачи диссертации и обзор методов оптимального управления	22
1.3 Методы машинного обучения для управления энергосистемами	30
1.4 Искусственные нейронные сети и их применение для задач управления режимами ЭЭС	42
1.5 Выводы по главе 1	53
ГЛАВА 2. Оценивание состояния и прогнозирование с использованием глубокого обучения	55
2.1 Статическое оценивание состояния	55
2.2 Динамическое оценивание состояния	56
2.3 Обоснование возможности прогнозирования параметров режима	58
2.4 Анализ динамики хаотического процесса	61
2.5 Прогнозирование режимов с использованием ИНС	66
2.5.1 Прогнозирование с использованием рекуррентных сетей LSTM	66
2.5.2 Применение Байесовских нейронных сетей	69
2.5.3 Пример использования разработанного алгоритма прогнозирования	71
2.6 Искусственная нейро-аналитическая сеть	77
2.6.1 Описание архитектуры нейро-аналитических сетей	77
2.6.2 Результаты обучения и прогнозирования с помощью нейро-аналитической сети	79
2.7 Выводы по главе 2	80
ГЛАВА 3. Оптимизация режимов электрических сетей при оперативном и автоматическом управлении	82
3.1 Архитектура системы оптимального управления ЭЭС	82
3.1.1 Описание модели верхнего уровня	82
3.2 Динамическая оптимизация режима	84
3.3 Детерминированная постановка задачи динамической оптимизации	88
3.3.1 Модель динамической оптимизации ЭЭС	88
3.3.2 Статическая оптимизация для каждого момента времени	88
3.3.3 Построение тестовой модели	89

3.4	Решение задачи динамической оптимизации в детерминированной постановке методом имитации отжига.....	89
3.5	Предлагаемый алгоритм динамической оптимизации	92
3.6	Особенности статической оптимизации в детерминированной постановке	95
3.6.1	О невыпуклости задачи оптимизации	95
3.6.2	Поиск глобального оптимума при статической оптимизации.....	97
3.6.3	Решение выпуклой задачи статической оптимизации.....	98
3.6.4	Дискретные управляющие воздействия.....	100
3.7	Вероятностная постановка задачи	102
3.7.1	Статическая оптимизация в вероятностной постановке	102
3.7.2	Динамическая оптимизация в вероятностной постановке.....	104
3.8	Вычислительный эксперимент оптимизации	105
3.8.1	Статическая оптимизация.	105
3.8.2	Динамическая оптимизация.	108
3.9	Выводы по главе 3	115
ГЛАВА 4.	Программная реализация	117
4.1	Области применения	117
4.2	Программная платформа	117
4.2.1	Архитектура взаимодействия программных модулей.....	118
4.2.2	Программная платформа для реализации ИНС	119
4.3	Система интеллектуального управления напряжением и реактивной мощностью в энергосистеме.....	120
4.3.1	Общее описание системы ИУНРМ.....	120
4.3.2	Архитектура системы	122
4.3.3	Управление электрической сетью	127
4.3.4	Взаимодействие с внешними подсистемами.....	127
4.3.5	Формирование среза в модели узлы/ветви	127
4.3.6	Просмотр результатов управления.....	129
4.3.7	Имитационная подсистема	132
4.4	Выводы по главе 4	135
Заключение	136
БИБЛИОГРАФИЧЕСКИЙ СПИСОК	138
Список использованных источников.....		138
Список публикаций соискателя по теме диссертационной работы		157
Приложение 1 Схема тестовой ЭЭС		161
Приложение 2 Пример результатов оптимизации за месяц		162
Приложение 3 Описание программной платформы АНАРЭС.....		182

Приложение 4 Акт о внедрении в ООО «Энергия-Т».....	186
Приложение 5 Акт о внедрении в ИрННТУ	187
Приложение 6 Свидетельство о государственной регистрации программы для ЭВМ «Блок динамической оптимизации ПВК АНАРЭС»	188

СПИСОК ИСПОЛЬЗУЕМЫХ СОКРАЩЕНИЙ

Русскоязычные сокращения:

АНАРЭС	– Программно-вычислительный комплекс для моделирования и анализа режимов энергосистем (http://anares.ru)
БСК	– Батареи статических компенсаторов
ВИЭ	– Возобновляемые источники энергии
ВПТ	– Вставка постоянного тока
ГА	– Генетические алгоритмы
ГЭС	– Гидроэлектростанция
ИНС	– Искусственные нейронные сети
ИРМ	– Источники реактивной мощности
ИУНРМ	– Интеллектуальное управление напряжением и реактивной мощностью
КПД	– Коэффициент полезного действия
НАС	– Нейро-аналитическая сеть
ПВК	– Программно-вычислительный комплекс
ПТК	– Программно-технический комплекс
РПН	– Регулирование под напряжением
ССПИ	– Система сбора и передачи информации
СТК	– Статический тиристорный компенсатор
СУБД	– Система управления базой данных
ТИ	– Телеизмерения
ТС	– Телесигналы
УР	– Установившийся режим
УШР	– Управляемый шунтирующий реактор
ЦУС	– Центр управления сетями
ШР	– Шунтирующий реактор
ЭЭС	– Электроэнергетическая система

Англоязычные сокращения:

AdaLIPO	– Adaptive Lipschitz optimization
AE	– Autoencoders
BBB	– Bayes By Backprop
BFGS	– Broyden - Fletcher - Goldfarb - Shanno algorithm
BM	– Boltzmann machines
CCRF	– Continuous Conditional Random Fields
CNN	– Convolutional neural networks

COM	– Component object model
CRF	– Conditional Random Fields
DAE	– Denoising autoencoders
DBN	– Deep belief networks
DCIGN	– Deep convolutional inverse graphics networks
DCNN	– Deep convolutional neural networks
DN	– Deconvolutional networks
DRN	– Deep residual networks
EKF	– Extended Kalman filter
ELM	– Extreme learning machines
FCRBM	– Factorized Restricted Boltzmann machine
FFNN	– Feed forward neural networks
GAN	– Generative adversarial networks
GRU	– Gated recurrent units
JSON	– JavaScript Object Notation
L-BFGS-B	– Limited memory BFGS with Bound restrictions
LIPOP	– Lipschitz optimization with probability
LSM	– Liquid state machines
LSTM	– Long short term memory
NMT	– Neural Turing machines
RBM	– Restricted Boltzmann machine
RHEL	– Red Hat Enterprise Linux
RL	– Reinforcement Learning
RNN	– Recurrent neural networks
SCADA	– Supervisory Control And Data Acquisition
SQL	– Structured query language
STATCOM	– Static synchronous compensator
subLBFGS	– Subgradient L-BFGS algorithm
SVM	– Support vector machine
SVR	– Support Vector Regression
UKF	– Unscented Kalman Filter
V2G	– Vehicle to grid
VAE	– Variational autoencoders
WAMS	– Wide area measurement system

ВВЕДЕНИЕ

Актуальность темы.

Задача поддержания режима работы энергосистемы в оптимальном состоянии является одной из основных задач оперативно-диспетчерского управления. Современные энергосистемы и интеллектуальные энергосистемы ближайшего будущего характеризуются наличием значительного количества элементов, режим которых является стохастическим во времени. Такое поведение энергосистем возникает за счет того, что в системе появляется значительное количество возобновляемых источников электроэнергии, а также локальных устройств управления, алгоритм работы которых не определен на уровне энергосистемы. Подробней о тенденциях развития энергосистем написано в главе 1 настоящей работы. Кроме того, задача ведения оптимальных режимов расширяется на сети низкого напряжения где охват сети измерительными приборами, а также согласованность измерений значительно ниже, чем в сети высокого напряжения. Вместе с тем, появляются новые возможности управления за счет скоординированного управления средствами компенсации реактивной мощности, а также устройствами регулирования напряжения.

До настоящего момента не существует комплексных решений, позволяющих в автоматическом режиме выполнять оптимизацию режима по напряжению и реактивной мощности с учетом прогноза изменения режима работы электрических сетей. Все существующие системы автоматического управления по своей сути являются реактивными, реагирующими на измеряемые отклонения контролируемых величин, таких как напряжения на шинах подстанций, перетоки мощности по линиям. Расчет оптимального режима основывается на параметрах текущего или наборе ретроспективных режимов. При этом, как правило, не учитывается, что указанное отклонение может носить кратковременный характер, и что для реализации управляющих воздействий (скоординированное переключение РПН, включение/отключение БСК, ШР) требуется достаточно длительное время.

Применяющиеся на практике методы прогнозирования режимов основаны на регрессионном анализе и выявлении длительных трендов в изменении режимов и используются для длительного планирования в энергосистеме в первую очередь с экономической точки зрения. Для оптимального управления электрическими режимами в темпе процесса требуются более быстродействующие модели, которые вместе с тем обеспечат прогноз на временной горизонт порядка суток.

Таким образом, в настоящий момент становятся востребованными алгоритмы оптимального управления, работающие в темпе процесса, в том числе, включаю-

щие прогнозирование режимов и динамическую оптимизацию электрических режимов сети с наличием элементов, поведение которых стохастично. Под темпом процесса понимается работа системы управления с быстродействием обеспечивающим оптимальное управление нормальным режимом с горизонтом прогнозирования порядка суток.

Цель и задачи исследований. Целью диссертационной работы является разработка методов прогнозирования и оптимизации нормальных электрических режимов электроэнергетических систем в темпе процесса оперативного и автоматического управления, а также реализация этих методов в виде программного прототипа.

Для достижения поставленной цели **сформулированы и решены следующие задачи:**

- 1) Обоснование необходимости применения методов машинного обучения для прогнозирования режимов электрических сетей со стохастическими элементами.
- 2) Исследование различных моделей машинного обучения и, в частности, архитектуры искусственных нейронных сетей на применимость к прогнозированию режимов электроэнергетических систем. Выбор наиболее эффективной структуры нейронных сетей для прогнозирования режимов.
- 3) Разработка новой модели искусственных нейронных сетей (Нейро-аналитическая сеть), позволяющей эффективно прогнозировать режим электрической сети большого объема.
- 4) Разработка метода стохастической оптимизации, основанного на алгоритме роя частиц.
- 5) Разработка метода динамической оптимизации нормальных электрических режимов электроэнергетических систем на основе метода стохастической оптимизации.
- 6) Разработка программного прототипа системы автоматического управления напряжением и реактивной мощностью в энергосистеме, реализующего разработанные методы прогнозирования и динамической оптимизации.

Объектом исследования являются электрические сети высокого напряжения в энергосистемах с наличием активной нагрузки и возобновляемых источников

электроэнергии. **Предметом исследования** являются методы прогнозирования и оптимизации нормальных электрических режимов, применяемые при оперативном и автоматическом управлении режимами электроэнергетических систем.

Теоретической и методологической основой диссертационной работы являются разработки отечественных и зарубежных ученых в области моделирования режимов ЭЭС, оценивания состояния, прогнозирования, оптимизации и машинного обучения.

Разработка методов анализа и управления электрическими режимами началась одновременно с созданием крупных объединенных энергосистем в 50-х годах прошлого века. Одновременно с этим, для решения в первую очередь экономических задач, развиваются методы линейного и выпуклого программирования и математической теории оптимального управления. Большой вклад в развитие методов оптимизации режимов энергосистем внесли ученые СЭИ (ИСЭМ) СО РАН. Активные исследования по разработке методов и средств автоматического и оптимального управления проводились уже начиная с 1970–80х годов.

Развитие методов оптимизации режимов энергосистем основывается на работах таких ученых, как: Понтрягин Л.С., Горнштейн В.М., Маркович И.М., Фазылов Х.Ф., Веников В.А., Идельчик В.И., Лебедев В.И., Пухов Г.Е., Руденко Ю.Н., Воропай Н.И., Крумм Л.А., Гамм А.З., Мурашко Н.А., Совалов С.А., Гончуков В.В., Баринов В.А., Арзамасцев Д.А., Бартоломей П.И., Холян А.М., Войтов О.Н., Кучеров Ю.Н., Дикин И.И., Колосок И.Н., Голуб И.И., Зоркальцев В.И., Хамисов О.В., Курбацкий В.Г. и др. В части оптимизации использовались работы Ю.Е. Нестерова, Р. Беллмана и других. В области машинного обучения использовались работы С.И. Николенко и других современных исследователей.

Информационную базу составляют монографические работы, материалы научно-технических конференций, объекты интеллектуальной собственности, статьи в периодических изданиях и научных сборниках по исследуемой проблеме.

Научная новизна. В результате выполнения работы получены следующие новые научные результаты:

- 1) Предложен способ оценки возможности прогнозирования режимов электроэнергетических систем с использованием эргодической теории и реконструкции динамической системы.
- 2) Разработана новая модель искусственных нейронных сетей – нейро-аналитическая сеть, позволяющая выполнять прогнозирование параметров электрических режимов крупной энергосистемы.

- 3) Разработан метод динамической оптимизации режимов ЭЭС со стохастическими элементами.
- 4) Предложен метод стохастической оптимизации процессов, развивающихся во времени.
- 5) Выполнена программная реализация системы оптимизации электрических режимов для оперативного и оптимального управления режимами.

Основные положения, выносимые на защиту:

- 1) Научное обоснование выбора модели машинного обучения для прогнозирования режимов ЭЭС.
- 2) Новая модель машинного обучения – искусственная нейро-аналитическая сеть.
- 3) Метод динамической оптимизации электрических режимов энергосистемы со стохастическими элементами.
- 4) Метод стохастической оптимизации процессов, развивающихся во времени, основанный на методе роя частиц.
- 5) Алгоритмы и структура программного обеспечения автоматического оптимального управления режимами ЭЭС.

Диссертация соответствует паспорту научной специальности 05.14.02 – «Электрические станции и электроэнергетические системы» в части:

- П.6 Разработка методов математического и физического моделирования в электроэнергетике;
- П.8 Разработка методов статической и динамической оптимизации для решения задач в электроэнергетике;
- П.13 Разработка методов использования ЭВМ для решения задач в электроэнергетике.

Методы исследования:

Работа выполнена с использованием: методов машинного обучения, искусственных нейронных сетей, методов статического и динамического оценивания состояния, эргодической теории динамического хаоса, теории нелинейного программирования, теории динамического программирования. Программная реализация выполнялась на языке программирования C++ с использованием библиотек Boost, Qt. Реализация искусственных нейронных сетей выполнялась на языке программирования Python с использованием библиотек Tensorflow, Keras, Deepmind Sonnet.

Практическая значимость и реализация результатов диссертационной работы. Предложенные методы, алгоритмы и программная реализация используются в следующих применениях:

- 1) Программное обеспечение «Подсистема оптимального управления напряжением и реактивной мощностью энергосистемы/энергорайона» используется как управляющая подсистема в составе программно-технического комплекса интеллектуального управления напряжением и реактивной мощностью для минимизации технологических потерь в электрической сети» (ПТК ИУНРМ) для Магаданской энергосистемы. Прототип сдан. В 2020-2021 годах выполняется наладка системы.
- 2) Блок динамической оптимизации ПВК АНАРЭС внедряется в Иркутской электросетевой компании в 2020-2021 годах.
- 3) Программное обеспечение автоматического оптимального управления режимами совместно с цифровым двойником энергосистемы, разработанном на основе ПВК АНАРЭС, используются в учебном процессе в Иркутском национальном исследовательском техническом университете.

Апробация работы. Основные положения и результаты диссертационной работы представлялись и докладывались на следующих научно-практических конференциях и семинарах:

- 1) Методические вопросы исследования надежности больших систем энергетики. Международный семинар им. Ю.Н. Руденко, в 2018 г., 2019 г., 2020 г.
- 2) Международная конференция "ENERGY-21: Sustainable Development & Smart Management", Сентябрь 7-11, 2020, Иркутск, Россия.
- 3) Всероссийское совещание по проблемам управления ВСПУ-2019. Институт проблем управления им. В.А. Трапезникова РАН, Москва, 2019.
- 4) International Workshop on Flexibility and Resiliency Problems of Electric Power Systems (FREPS 2019), Иркутск, Байкал, 26-31 Августа 2019 г.
- 5) 2nd IEEE Conference on Energy Internet and Energy System Integration, Пекин, Китай, 20-22 Октября 2018 г.

Достоверность полученных результатов работы. Обоснованность и достоверность связана с использованием классических расчетных методов и алгоритмов расчета, а также проверкой и сопоставлением предлагаемых методик с классическими. Адекватность используемой математической модели ЭЭС подтверждается соответствием реальным принципам функционирования электроэнергетической

системы, экспертной оценкой специалистов службы электрических режимов электросетевой компании, а также согласованностью с результатами, полученными при использовании других программных комплексов.

Публикации. По теме диссертации опубликовано 21 работа в том числе, 3 статьи в рецензируемых научных журналах рекомендуемых ВАК РФ по специальности 05.14.02 [A1 - A3], 3 статьи в журналах рекомендуемых ВАК по другим специальностям [A4 - A6], 4 статьи, индексируемые в SCOPUS и Web Of Science [A7-A9], главы в реферируемых монографиях [A10 - A14]. Получено 1 свидетельство о регистрации программы для ЭВМ (Приложение 6).

Объем и структура диссертации. Диссертационная работа состоит из четырех глав, списка сокращений, введения, заключения, списка использованных источников и приложений. Работа содержит 137 стр. основного текста, 79 рисунков и 3 таблицы. Библиография включает 251 наименование.

Личный вклад. Постановка задач и анализ результатов работы обсуждались с научным руководителем. Все теоретические, методические и программные разработки выполнены лично соискателем.

Содержание диссертационной работы.

Во введении показана актуальность работы, сформулирована её цель, определена научная новизна исследований, показана практическая значимость и перечислены области ее применения, представлены положения, выносимые на защиту, дается краткое содержание работы.

В первой главе «Обзор методов оптимального управления электрическими режимами и применения методов обучения для управления энергосистемами» рассмотрены современные тенденции в развитии энергосистем. Показано увеличение сложности энергосистем и как следствие необходимость более оперативного управления режимами таких энергосистем, а в идеале автоматического оптимального управления.

В главе рассмотрено развитие методов оптимального управления электрическими режимами и, в частности, методов оптимизации. Показано, что методы статической детерминированной оптимизации хорошо проработаны. Что касается задачи оптимизации электрических режимов в реальном времени с учетом стохастического поведения энергосистем, то несмотря на множество работ в этом направлении, решение этой задачи для систем большой размерности все еще остается открытой проблемой. Возможным решением видится применение адаптивного ме-

тогда прогнозирования совместно со стохастическим методом динамической оптимизации. Для обеспечения адаптивности применяемый метод прогнозирования должен автоматически подстраиваться под текущее состояние системы и выявлять неявные зависимости между параметрами системы. Поэтому далее в главе рассматриваются различные модели машинного обучения и анализируется их применимость к задачам оптимального управления нормальными электрическими режимами энергосистем.

Рассмотрено применение различных методов машинного обучения применительно к задачам электроэнергетики и в частности к задачам оценивания состояния и прогнозирования электрических режимов. Приведена классификация методов машинного обучения, где каждый метод рассматривается применительно к задачам, требуемым в оптимальном управлении нормальными режимами энергосистем.

Для классических методов машинного обучения выделены несколько направлений в электроэнергетике, в которых они применяются, это: классификация режимов, прогнозирование, фильтрация данных и кластеризация. Для классификации и выявления опасных режимов применяются такие методы, как: деревья принятия решений, случайный лес, бустинг, условные случайные поля. Для прогнозирования применяются: метод опорных векторов, метод главных компонент, метод релевантных векторов, различные виды регрессии. Для фильтрации сигналов, в том числе в задаче динамического оценивания состояния, применяются различные варианты фильтра Калмана.

Далее в главе приведена классификация методов обучения с подкреплением, а также показана ограниченность их применения для задач управления электрическими режимами.

В качестве одного из направлений машинного обучения рассматриваются искусственные нейронные сети (ИНС). Различные архитектуры ИНС проанализированы на предмет возможности применения для задач оптимального управления электрическими режимами и, в частности, для задачи оценивания состояния и прогнозирования режимов. Отмечено, что большинство вариантов применения ИНС для данных задач ограничивается применением полносвязанных ИНС с достаточно малым количеством скрытых слоев и проверено на небольших схемах. В качестве наиболее подходящей из существующих архитектур ИНС для оценивания состояния и прогнозирования режимов выбрана архитектура рекуррентных нейронных сетей LSTM.

Во второй главе «Оценивание состояния и прогнозирование с использованием глубокого обучения» описаны результаты разработки моделей для динамического оценивания состояния и прогнозирования режимов.

В начале главы проводится исследование классических методов динамического оценивания состояния, основанных на модификациях фильтра Калмана. Проведено тестирование этих методов на примере реальной энергосистемы с использованием измерений, получаемых от SCADA-системы. Показаны ограничения применения классических методов динамического оценивания состояния.

Проведены исследования эволюции электрических режимов во времени, как динамической системы с неизвестным законом управления. Применена эргодическая теория для качественной оценки прогнозируемости электрических режимов ЭЭС.

Показана возможность применения глубоких ИНС на основе ячеек LSTM для прогнозирования режимов. Вместе с тем, показана проблема возрастания вычислительной сложности при прогнозировании большого количества параметров, что фактически необходимо для использования в задаче оптимального управления.

Предложена архитектура нейро-аналитических сетей, которая решает проблему применения глубоких LSTM сетей для прогнозирования режимов больших энергосистем в реальном времени.

В третьей главе «Оптимизация электрических режимов при оперативном и автоматическом управлении» исследованы методы оптимизации, которые могут быть применены в электрических сетях с наличием активной нагрузки.

Разработан алгоритм стохастической оптимизации динамического процесса, позволяющий эффективно находить набор оптимальных воздействий с учетом составляющей целевой функции, зависящей от времени. Алгоритм основан на принципах оптимизации методом роя частиц.

Сформулирована задача динамической оптимизации с учётом вероятностного характера параметров электрического режима. Предложено использование интервальной арифметики для быстрой оценки распределения вероятности вектора состояния при решении задачи расчета установившегося режима в вероятностной постановке.

Для статической оптимизации, используемой для каждого момента времени в процессе динамической оптимизации показана невыпуклость целевой функции. Предложен алгоритм поиска областей локального оптимума с помощью стохастического алгоритма глобальной оптимизации Липшецевой функции и дальнейшее

решение задачи оптимизации в окрестности найденного локального минимума квази-ньютоновским методом оптимизации LBFGSB.

Предложенный метод динамической оптимизации опробован на примере реальной энергосистемы и показал свою эффективность. Входными данными для расчетов являлись режимы, оптимизируемые службой электрических режимов, на основе текущих и планируемых данных. Полученные результаты динамической оптимизации близки к теоретическому минимуму, полученному по результатам статической оптимизации, при которой учитывалась стоимость управляющих воздействий.

В четвертой главе «Программная реализация» приведено описание программного обеспечения, реализующего представленные методы прогнозирования и оптимизации нормальных электрических режимов энергосистем при оперативном и автоматическом управлении.

Приведены примеры применения программной реализации представленных методик. Представлена программная платформа, на которой была выполнена реализация алгоритмов оптимального управления, в том числе описание пользовательского и программного интерфейса.

Описана реализация прототипа промышленной системы автоматического интеллектуального управления напряжением и реактивной мощностью в энергосистеме.

ГЛАВА 1. ОБЗОР МЕТОДОВ ОПТИМАЛЬНОГО УПРАВЛЕНИЯ ЭЛЕКТРИЧЕСКИМИ РЕЖИМАМИ И ПРИМЕНЕНИЯ МЕТОДОВ ОБУЧЕНИЯ ДЛЯ УПРАВЛЕНИЯ ЭНЕРГОСИСТЕМАМИ

В данной главе показана необходимость применения адаптивных методов для оптимального управления режимами ЭЭС и, в частности, методов машинного обучения. Далее приводится обзор методов оптимального управления режимами электроэнергетических систем и современных методов машинного обучения, применительно к решению электроэнергетических задач. Исходя из обзора выбрана архитектура построения системы оптимизации при оперативном и автоматическом управлении, основу которой составляет динамическая оптимизация на основе прогноза. Также на основе обзора выбрана наиболее подходящая модель машинного обучения для прогнозирования электрических режимов.

1.1 Современные тенденции в развитии энергосистем

Уже более десяти лет во многих странах развивается концепция так называемых интеллектуальных (“умных”) электрических сетей (Smart Grids) [1, 2]. Данная концепция включает рассмотрение таких вопросов, как:

- применение силовых элементов ЭЭС, имеющих в своем составе компьютерные (цифровые) устройства управления и использующиеся для производства, накопления, передачи, распределения и потребления электроэнергии;
- применение современных информационно-коммуникационных технологий в управлении ЭЭС;
- новые методы управления ЭЭС, использующие, в том числе комплексные вычислительные алгоритмы и машинное обучение;
- применение регулирующих устройств, обеспечивающих активное поведение потребителей по управлению собственным электропотреблением;
- использование возобновляемой и малой распределенной генерации.

Отдельно следует отметить вопрос, касающийся распределенной генерации. В настоящее время по всему миру внедряются источники возобновляемой энергии, такие, как ветрогенераторы и солнечные электростанции. Рост доли возобновляемых источников электроэнергии можно видеть на Рис. 1.1. Данный прогноз взят из отчета «Международная Энергетическая Перспектива 2018» агентства Energy Information Administration федеральной статистической системы США [4].

Такая тенденция существует благодаря двум противоположным факторам. С одной стороны технологии ВИЭ с учетом их достаточно высокой стоимости становятся востребованными на фоне устаревания основных энергетических фондов и либерализации энергетики. С другой стороны, имеется и положительный фактор

научного прогресса, благодаря которому ветрогенераторы и солнечные электростанции могут обеспечивать уже приемлемый КПД. При этом, мощность, генерируемая таким источниками энергии, не является постоянной величиной и зависит от природных условий: наличия ветра, активности солнечного излучения и т. д. В результате такая нестабильность генерации ВИЭ отрицательно влияет на устойчивую работу электроэнергетической системы и усложняет прогнозирование и оптимизацию режимов ЭЭС. Поэтому классический принцип организации управления электроэнергетическими системами, когда режим заранее планируется и управление производится вручную, не подходит для ЭЭС с большой долей ВИЭ [3].

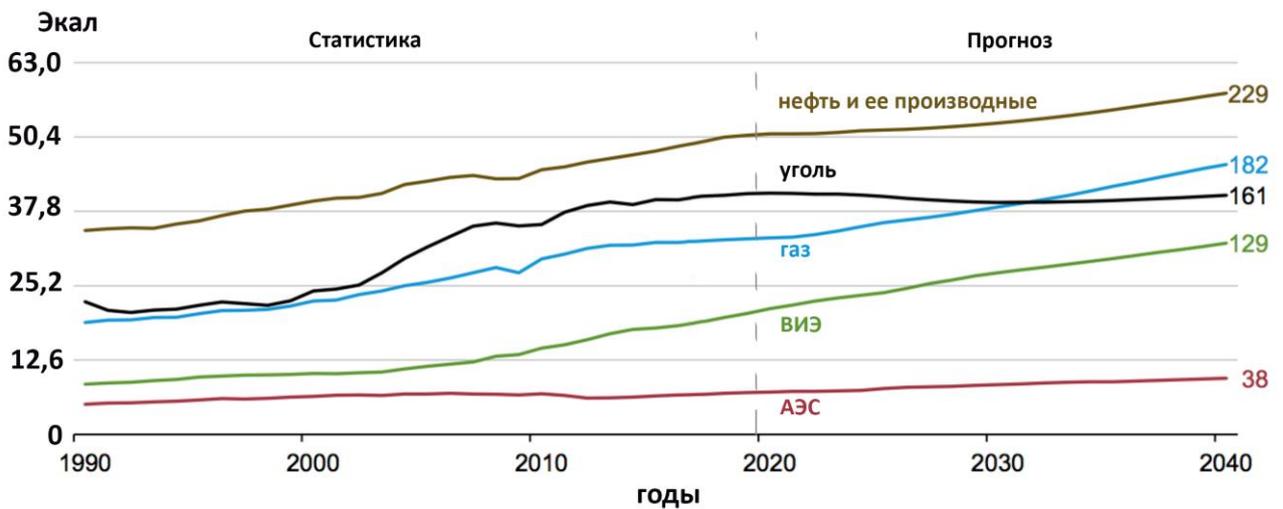


Рис. 1.1 – Прогноз объемов различных типов энергоносителей

Еще одна важная тенденция, которую надо учитывать при анализе развития электроэнергетических систем, это развитие электрического автотранспорта. В настоящее время ископаемые виды топлива являются основными источниками энергии для автомобильного транспорта. Истощение запасов ископаемого топлива побуждает к поиску альтернативных источников энергии для автомобилей. Кроме того, сжигание ископаемого топлива приводит к образованию парниковых газов, которые оказывают значительное влияние на изменение климата. Согласно отчету [5], до 2035 года потребление нефти в транспортном секторе увеличится на 54%. Цена на нефть при этом продолжит расти в течение следующих двух десятилетий. В связи с этим в мире предпринимаются усилия, связанные с сокращением потребления нефти, одно из которых – это электромобили. В будущем рост доли электрических автомобилей будет только увеличиваться. Так, например, во время конференции по климату в Париже в 2015 году, где была принята совместная инициатива “Парижская декларация по электромобильности и изменению климата и призыв к

действиям”. Для достижения целей, заданных данной декларацией, электромобили должны представлять 35% мировых продаж автомобилей к 2030 году [6].

Электромобили вносят дополнительную индетерминированную составляющую в поведение ЭЭС, что негативным образом отражается на ее моделировании и управлении ЭЭС. Когда электромобили подключаются к электрической сети не согласованно и на полную мощность, требуемую для зарядки (например 4 кВт), то такое нескоординированное поведение приводит к возникновению местных проблем с режимами ЭЭС, таких, как дополнительные потери электроэнергии, отклонения напряжения и тем самым к ухудшению качества электроэнергии, потенциальному снижению устойчивости ЭЭС.

Для качественной оценки потенциального влияния электромобилей на электрические сети была оценена доля участия электромобилей в общей нагрузке электрических сетей на основе следующих открытых статистических данных:

- данные о количестве автомобильного транспорта на душу населения [7];
- статистические данные и прогноз населения по странам [8];
- статистические данные и прогноз потребления электроэнергии по странам [9, 10].

Также был экстраполирован рост объемов продаж электромобилей [11] с учетом текущей тенденции и декларируемой доли в 35% от общего объема продаж автомобилей.

В результате на примере потребления электроэнергии таких стран, как Россия, США, Франция и Германия (Рис. 1.2) доля прогноза потребления электромобилей оказывается существенной и достигает до 25% (Рис. 1.3). Приведенные данные не учитывают возможное насыщение рынка автомобилей, но для качественной оценки такой подход допустим.

Таким образом, интеллектуальные энергосистемы с точки зрения их моделирования характеризуются наличием значительного количества элементов, режим которых является стохастическим во времени. Перечислим основные компоненты ЭЭС, вносящие неопределенность в модель системы:

- 1) Альтернативные источники генерации: ветрогенераторы и солнечные электростанции.
- 2) Изменчивость бытовой нагрузки и, в том числе, адаптивной нагрузки.
- 3) Зарядные станции для электромобилей.
- 4) Аккумулирующие устройства, в том числе технология Vehicle-to-grid (V2G) — концепция двухстороннего использования электромобилей и

гибридов, подразумевающая подключение машины в общую электрическую сеть для подзарядки автомобиля с возможностью выдачи электроэнергии обратно в сеть.

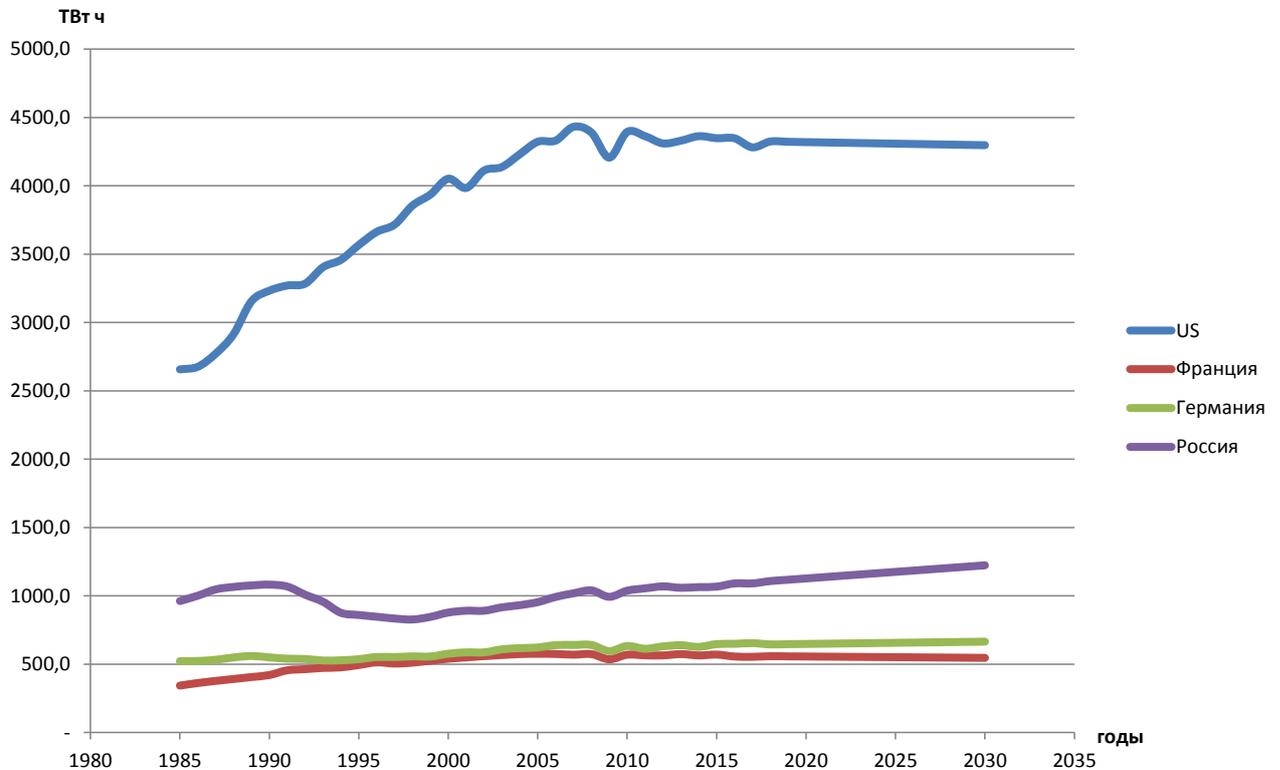


Рис. 1.2 – Прогноз электропотребления

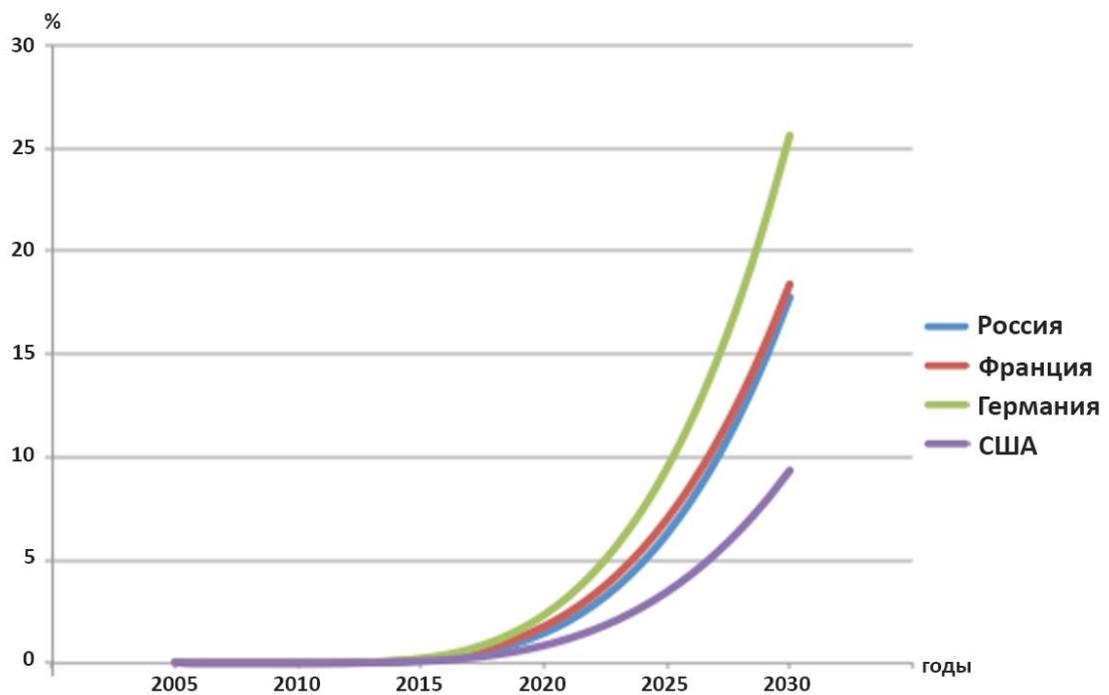


Рис. 1.3 – Рост доли электромобилей в объеме нагрузки электрических сетей в процентах

Далее определим характер неопределенности для каждого из перечисленных компонентов.

Ветровые электростанции

Генерируемая мощность ветрогенератора зависит от скорости ветра. Скорость ветра в свою очередь изменяется даже в течение минут. Для описания изменчивости ветрогенерации используются вероятностные модели, использующие распределение Вейбулла [12, 13], плотность вероятности которого описывается, как:

$$W(v) = \frac{K}{c} \left(\frac{v}{c}\right)^{K-1} e^{-\left(\frac{v}{c}\right)^K}, \quad (1.1)$$

где c – масштабный коэффициент Вейбулла, K – коэффициент формы распределения Вейбулла, v – скорость ветра.

Мощность генерации ветровой электростанции определяется по кривой зависимости мощности турбины от скорости ветра [12], исходя из скорости ветра, полученной по выборке (1.1).

Солнечные электростанции

Мощность генерации солнечных панелей определяется по значениям солнечной радиации и температуры воздуха [12, 14].

$$P_{PV} = P(G) \left(1 / (1 + \gamma(T - T_0))\right), \quad (1.2)$$

где G – значение солнечной радиации; P – зависимость мощности выдаваемой солнечной панелью от солнечной радиации; T – температура фотоэлектрического модуля; T_0 – стандартная температура модуля; γ – коэффициент влияния температуры.

Кроме стохастических параметров солнечной радиации и температуры, фактически на выработку солнечной электростанции в целом влияет алгоритм локального управления солнечной электростанцией, который управляет зарядкой и разрядкой аккумуляторов.

Бытовая нагрузка

Модель нагрузки, как правило, задается нормальным распределением со средним значением μ и стандартным отклонением σ . Появление интеллектуальных счетчиков в распределительных сетях привносит некоторые новые аспекты в задачу прогнозирования нагрузки. «Умные» счетчики облегчают взаимодействие в реальном времени между поставщиком электроэнергии и домохозяйствами, обеспечивая сбор данных с большей частотой. Вместе с тем, эти данные в большой сте-

пени не согласованы друг с другом по времени, что добавляет сложности для прогнозирования нагрузки в таких сетях. Дополнительную стохастичность в модель нагрузки вносит активная нагрузка. На уровне энергосистемы закон управления активной нагрузкой не определен и приближенно ее можно учесть увеличенным значением дисперсии.

Электромобили

Рост доли электрического автомобильного транспорта начинается после 2010 года. Большинство публикаций, авторы которых исследуют влияние зарядки электромобилей на электрические сети, рассматривают модели процесса зарядки электромобилей, подключенных в конкретных местах рассматриваемой электрической сети (детерминированный подход) [15 – 18, 20]. Также достаточно большое количество работ посвящено оптимизации мест установки зарядных станций [19, 25].

Однако, для целей управления режимами ЭЭС большой интерес представляют вероятностные модели определения загрузки электрических сетей с учетом влияния зарядных станций электромобилей. При этом, как правило, делались определенные частные предположения о характере подключения электромобилей к сети. Так в [21] время и продолжительность подключения для каждого электромобиля определялись моделью его передвижения в течение всего года. В [22] использовались суточные графики нагрузок, конкретные модели передвижения электромобилей и среднее время зарядки. В [23] модели зарядки электромобилей были получены из модели движения обычных транспортных средств.

Наиболее полно, с точки зрения автора, модель влияния электромобилей на нагрузку электрических сетей представлена в работе [24]. В данной работе рассматривается вероятностный расчет установившегося режима. В работе рассматривается вероятностная модель единичного электромобиля, в которой дневное перемещение автомобиля задается через логнормальное распределение. Исходя из дневного перемещения рассчитывается потребность в электроэнергии. Для построения модели множества электромобилей, которые могут заряжаться от электрической сети используется теория массового обслуживания.

Если выше рассматривались только варианты однонаправленного подключения электромобилей к сети, когда электромобили представляются только в виде нагрузки в процессе зарядки батарей, то в последнее время всё более возрастающий интерес представляет технология использования электромобилей, как накопителей электроэнергии с возможной выдачей электроэнергии в сеть. Такая технология получила название в зарубежной литературе – Vehicle To Grid (V2G). Действительно,

при всей своей эффективности, электрический транспорт представляет дополнительную проблему для электрических сетей в связи со своей мобильностью и нерегулярностью. Технология V2G позволит компенсировать негативное влияние электрического транспорта на устойчивость работы ЭЭС и при должном объеме даже повысить ее гибкость. Исследования показали, что большинство автомобилей припаркованы почти 95% времени. В этом случае они могут оставаться подключенными к сети и быть готовы поставлять энергию, хранящуюся в их батареях, в соответствии с технологией V2G, впервые описанной В. Кэмптоном [26]. Большинство работ, касающихся технологии V2G, затрагивают вопрос построения алгоритмов оптимизации и управлением зарядкой электротранспорта, стимулирующих пользователей электротранспорта отдавать энергию в сеть, когда в этом есть потребность в ЭЭС [27 – 30]. При этом применяются следующие целевые функции: минимизация потерь в сети; максимизация экономического эффекта; минимизации стоимости управления; минимизация отклонения кривой потребления от заданной; минимизация выбросов парниковых газов; максимизация возобновляемой генерации [31 – 40].

Описываемые тенденции показывают увеличение сложности энергосистем и как следствие необходимость более оперативного управления режимами таких энергосистем, а в идеале автоматического оптимального управления. Современные тенденции в развитии ЭЭС приводят к тому, что несмотря на развитие средств мониторинга, поведение ЭЭС становится менее прогнозируемым. Для компенсации этого системы управления ЭЭС должны становиться все более «умными».

В следующем разделе описывается постановка задачи оптимального управления и ее развитие.

1.2 Постановка задачи диссертации и обзор методов оптимального управления

Задачи оптимального управления электрическими режимами являются одними из наиболее важных и хорошо изученных направлений исследований в энергетике. Под оптимальным управлением здесь понимается весь спектр задач, включающий планирование режимов и автоматическое и автоматизированное диспетчерское управление. Как правило, в основе оптимального управления лежит задача нахождения оптимального потокораспределения, заключающаяся в нахождении минимума целевой функции за счет изменения свободных переменных системы, с учетом сетевых ограничений и ограничений на свободные параметры системы. Для

единичного статического режима эта задача может быть сформулирована следующим образом.

$$\min_x f(x, y) \left| \begin{array}{l} b(x) \leq 0 \\ g(x, y) = 0 \end{array} \right. \quad (1.3)$$

где $f(x)$ – целевая функция задачи оптимизации; x – вектор свободных переменных, являющихся управляющими параметрами оптимизации; y – параметры системы независимые от управляющих параметров x ; $g(x, y)$ – сетевые ограничения; $b(x)$ – ограничения на управляющие параметры.

Целевая функция – это, как правило, суммарные технологические потери и стоимость генерации. Подробней целевая функция оптимизации сформулирована в главе 3.

Для оптимизации электрических режимов в темпе процесса управления, задача усложняется тем, что необходимо не только найти оптимальное значение управляющих параметров, но и время их применения, то есть вектор свободных параметров задается функцией, зависящей от времени.

$$x = x(t).$$

С учетом стохастического поведения ЭЭС задача в общем виде может быть записана, как:

$$\min_x \int_{-T_p}^{T_f} \Phi(x, \dot{x}, \mathbb{E}(\xi(t)), y(t)) dt \left| \begin{array}{l} b(x) \leq 0 \\ g(x, y(t), \mathbb{E}(\xi(t))) = 0 \end{array} \right. \quad (1.4)$$

Здесь в отличии от статической постановки оптимизации минимизируется функционал на заданном интервале времени. T_p – глубина учета прошлых моментов времени, T_f – горизонт времени на который имеется прогноз изменения параметров режима $y(t)$. Кроме того, в данной постановке учитывается вероятностная составляющая $\xi(t)$, отражающая стохастическое поведение системы. Учет вероятностной составляющей возможен через ее математическое ожидание в каждый момент времени $\mathbb{E}(\xi(t))$. В общем виде решение данной задачи вычислительно сложно, так как она является большеразмерной, невыпуклой и с наличием вероятностных величин.

Чтобы проследить историческое развитие методов оптимального управления нормальными режимами ЭЭС, приведем их укрупненную классификацию (Рис. 1.4).

Развитие методов оптимального управления электрическими режимами началось с планирования режимов. Все параметры режимов при этом задавались детерминировано.

Разработка методов анализа и управления электрическими режимами началась одновременно с созданием объединенных крупных энергосистем в 50-е годы 20-го века [41 - 46]. Одновременно с этим для решения в первую очередь экономических задач развиваются методы линейного и выпуклого программирования и математической теории оптимального управления [47, 48]. Возможности применения методов оптимизации на практике поспособствовало появление первых вычислительных машин. Активные исследования по разработке методов и средств автоматизированного управления ЭЭС проведены в Сибирском энергетическом институте (СЭИ) в 1970 – 80 е годы [49 - 54].



Рис. 1.4 – Классификация методов оптимального управления нормальными электрическими режимами

В настоящий момент существуют эффективные методы решения задачи выпуклой оптимизации [55], применяемые для статической оптимизации электрических режимов ЭЭС.

- Методы внутренней точки для решения выпуклой оптимизации с ограничениями. Впервые данный метод был предложен И.И. Дикиным [56] и алгоритмически развит рядом авторов [57 - 60].
- Квазиньютоновские методы нелинейной оптимизации [206, 220, А20].

При оптимизации электрических режимов зачастую принимается допущение о выпуклости задачи оптимизации [49], что может быть допустимо в случае поиска оптимального решения от достаточно близкой к оптимальной начальной точке. В

случае невыпуклой задачи оптимизации, как это есть в общем случае при оптимизации режимов с учетом ограничений, могут применяться двойственные методы для выпуклой релаксации задачи оптимизации [211].

Методы статической детерминированной оптимизации электрических режимов применяются для планирования режимов. Периодичность планирования, как правило, сезонная и при планировании ремонтных работ.

До конца 1990-х годов большинство исследований в области оптимизации электрических режимов не учитывало вероятностный характер поведения энергосистем с наличием активной нагрузки и ВИЭ. Однако, с началом распространения таких элементов в энергосистемах активизировались и исследования оптимизации режимов с учетом вероятностного поведения ЭЭС. В зарубежной литературе этот термин получил название Probabilistic Optimal Power Flow (POPF).

Для оптимизации в условиях неопределенности было разработано множество робастных методов [61], применимых в конкретных, как правило локальных задачах. В постановке задачи робастной оптимизации неопределенные переменные описываются как случайные значения в определенных интервалах [62].

Другим вариантом оптимизации с учетом вероятностного характера переменных режимов являются методы оптимизации с вероятностными ограничениями [63 – 68]. В постановке задачи оптимизации с вероятностными ограничениями неопределенные переменные описываются как случайные величины с определенными стохастическими распределениями. При этом, если принято допущение о линейности модели электрической сети, а случайные величины распределены нормально, существует эквивалентное детерминированное представление [64]. Модель сети является линейной, например, при оптимизации в рамках решения задачи балансовой надежности. Для оперативного управления электрическими режимами, рассматриваемого в данной работе, модель электрической сети не линейна. В этом случае задача оптимизации с учетом вероятностных ограничений решается с использованием методов аппроксимации, например, приближения выборочного среднего [69], обратного отображения [70, 71] и внутреннего-внешнего приближения [72, 73].

Подходы для оптимального управления режимами к настоящему времени можно разделить на две категории (Рис. 1.4):

- 1) Ввод в режима в заранее посчитанные ограничения. Существует множество работ, использующих данный подход. Полученные таким образом решения могут быть неоптимальными и используются для решения локальных задач оптимизации, например для оптимизации на уровне адаптивной нагрузки.

2) Оптимальное управление на основе алгоритмов оптимизации.

Основная идея оптимизации электрического режима в реальном времени состоит в том, чтобы реагировать на колебания параметров электрического режима в каждый момент времени, причем эти реакции в определенный момент времени могут быть как оптимальными, так и неоптимальными. Это отличается от автономной оптимизации (детерминированной и стохастической), где оптимальные управляющие воздействия рассчитываются только один раз для каждого момента времени.

В 1988 году в работе [74] была представлена концепция и математическая формулировка оптимизации электрических режимов в реальном времени. Данная работа была основана на методе квадратичной оптимизации и ограничена использованием только линейной модели. В дальнейшем было проведено множество исследований в данном направлении, однако, в связи со сложностью задачи в общей постановке, решение как правило ограничивалось локальной постановкой. Например, в [75] предложен подход на основе проекции градиента между временными срезами. Данное решение применяется для динамической оптимизации радиальных распределительных сетей. Метод основан на квазипоследовательном подходе, предложенном в [76], который был усовершенствован в другом исследовании [77]. В работе [78] предложена почасовая диспетчеризация электроэнергии на основе последовательных срезов данных. Этот метод использует линейную модель и вероятностный метод оптимизации для учета неопределенности ВИЭ.

В работе [79] для оптимизации в реальном времени используется машинное обучение на основе полно-связанных нейронных сетей. Использование ИНС позволило добиться высокой скорости оптимального управления, но ограничено лишь некоторым ограниченным количеством сценариев, на которых проходило обучение.

Наиболее близка к решаемой задаче оптимального управления в темпе процесса задача много-периодической оптимизации, применяемая при вычислении оптимальных стратегий работы накопителей электроэнергии, установленных в изолированной электрической сети. Данной задаче посвящено множество работ, например, [244 – 247]. Обобщенная целевая функция много-периодической оптимизации электрических режимов энергосистемы с наличием накопителей электроэнергии может быть записана, как:

$$\min_{x(t)} \sum_{t=t_0}^T f_t(x, y, c(t)) \left| \begin{array}{l} b(x) \leq 0 \\ g(x, y) = 0 \\ s(c(t)) \leq 0 \end{array} \right.$$

В отличие от статической постановки задачи оптимизации (1.3) в задаче много-периодической оптимизации минимизируется сумма целевых функций на каждом временном диапазоне. При этом, задача усложняется тем, что присутствуют интегральные ограничения s зависящего от времени параметра $c(t)$. Применительно к оптимизации заряда накопителей параметр $c(t)$ – это состояние заряда батарей. В отличие же от постановки задачи динамической оптимизации (1.4), рассматриваемой в данной работе, процесс управления принимается Марковским, а изменения зависящего от времени параметра – непрерывными.

В работках [245 – 247] для решения этой задачи применяются аналитические методы Лагранжевой релаксации. В работе [244] применяется двухуровневое программирование. Есть решения представленной задачи с использованием Марковского процесса принятия решений [249], динамического программирования [248], стохастической оптимизации методом имитации отжига [250]. В работе [251] в много-периодической оптимизации используется предварительно полученный прогноз возобновляемой генерации. Отличительной особенностью всех предлагаемых решений является то, что они ориентированы на оптимизацию режимов достаточно небольшой (менее 100 узлов) и, как правило, изолированной сети.

В рамках диссертационной работы рассматривается задача оптимального управления электрическими режимами крупной энергосистемы. При этом, задача ограничена оптимизацией нормальных электрических режимов электроэнергетических систем в темпе процесса. Под темпом процесса понимается работа системы управления с быстроедействием, обеспечивающим оптимальное управление текущим режимом с горизонтом управления порядка нескольких суток. Частота реализации управляющих воздействий для этой задачи не высока, и составляет несколько воздействий в сутки для устройств управления в сети высокого напряжения. Сложность данной задачи в том, что в целевой функции для каждого отдельного момента времени учитывается составляющая, зависящая от прошлой траектории изменения управляющих параметров, что делает процесс не Марковским. Кроме того, оптимальное управление реального времени с учетом стохастического поведения ЭЭС является задачей динамического смешанно-целочисленного нелинейного программирования с учетом неопределенностей параметров системы.

Рассматриваемая сеть ограничена только моделью сети высокого напряжения, в которой активная нагрузка и возобновляемая генерация представлены стохастиче-

ческими величинами с известными нормальными или приведенными к нормальному распределению вероятности. В таблице 1.1 приведено укрупненное сравнение методов применимых для данной задачи.

Таблица 1.1. Сравнение вариантов оптимизации для целей оперативного и автоматического управления

Вариант оптимизации	Особенности	Преимущества	Недостатки
Статическая оптимизация	Период оптимизации достаточно большой (в среднем раз в месяц), так как проводится для типовых планируемых режимов. Основной подход, используемый сейчас на практике.	Хорошо проработанные эффективные методы оптимизации, в том числе в вероятностной постановке.	Большой период оптимизации, в результате чего не полностью используются технические возможности по регулированию режимов.
Динамическое программирование	Применение для процессов, обладающих Марковскими свойствами. Управление в темпе процесса на небольшой горизонт в будущем.	Высокое быстродействие. Нет необходимости в отдельном методе прогнозирования.	Применимо только для локальных задач оптимального управления.
Много-периодическая оптимизация методами релаксации	Работают на основе прогноза. Использование эффективных методов статической оптимизации для двойственной задачи.	В результате находится обоснованный минимум.	Ограничено небольшим объемом решаемой задачи (до 100 узлов). Возможны ситуации вырожденности Якобиана при решении двойственной задачи. Применяются для

			оптимизации задач с непрерывной целевой функцией, с учетом ограничений.
Стохастические методы много-периодической оптимизации	Работают на основе прогноза. Используют универсальные методы стохастической оптимизации с учетом времени.	Простые интуитивно-понятные алгоритмы. Возможность решения большого спектра оптимизационных задач.	Большая вычислительная сложность для не Марковских процессов. Поэтому применение ограничено локальными задачами небольшого объема.

Оптимизация нормальных электрических режимов электроэнергетических систем в темпе процесса включает в себя и задачу прогнозирования. Общая схема работы алгоритма оптимального управления, для рассматриваемой задачи представлена на Рис. 1.5. Исследуемые в диссертационной работе вопросы, представленные на данном рисунке, это: прогнозирование режимов и динамическая оптимизация на основе прогноза.



Рис. 1.5 – Общая структура алгоритма оптимизации при оперативном и автоматическом управлении режимами

Для решения проблемы изменчивости модели ЭЭС можно использовать адаптивные алгоритмы оценивания состояния и прогнозирования режимов, автоматически подстраивающихся под текущее состояние системы и выявляющих неявные зависимости между параметрами системы. Поэтому в следующем разделе рассмотрены модели машинного обучения и их применимость к задачам оптимального управления в энергосистемах и, в частности, оценивания состояния, прогнозирования режимов и оптимизации. При рассмотрении методов машинного обучения не делался фокус только на задачах прогнозирования и оптимизации, так как есть применения методов машинного обучения для комплексного оптимального управления в энергосистемах.

1.3 Методы машинного обучения для управления энергосистемами

Машинное обучение – это класс методов искусственного интеллекта, характерной чертой которых является не прямое решение задачи, а обучение модели на множестве решений и данных. Для построения таких методов используются средства математической статистики, численных методов, методов оптимизации, теории вероятностей, теории графов, различные техники работы с данными.

На Рис. 1.6 приведена классификация методов машинного обучения. Все методы обучения условно разделены на четыре группы:

- 1) Классические методы – методы исторически появившиеся первыми и основанные, в основном, на законах статистики. Характеризуются достаточно очевидными признаками и целевыми функциями, используемыми при обучении.
- 2) Обучение с подкреплением – методы машинного обучения, применяющиеся, когда вместо массивов данных имеется модельная среда, во взаимодействии с которой и происходит обучение модели.
- 3) Ансамблевые методы – методы, использующие несколько методов первых двух групп или несколько экземпляров одного метода таким образом, что отдельные алгоритмы дополняют друг друга, исправляя ошибки, конкурируя или проверяя. Развитие данных методов произошло благодаря развитию вычислительных мощностей компьютерной техники. В ансамбле могут одновременно работать сотни или даже тысячи экземпляров простых моделей.

- 4) Искусственные нейронные сети. Позволяют выявить сложные взаимосвязи в исходных данных и получить более качественный результат, но, как правило, требуют больших вычислительных ресурсов для обучения. Подробнее искусственные нейронные сети будут описаны в следующем разделе данной главы.

Еще одно важное разделение методов машинного обучения – это разделение на методы с учителем и методы без учителя. В методах с учителем модель обучается на наборе данных, когда для каждого рассматриваемого примера имеется готовое решение. Это может быть результат натуральных измерений или результат работы численной модели. В методах обучения без учителя исходные данные никак не размечены и алгоритм обучения сам выявляет закономерности в данных. На представленной схеме группы методов с учителем и без выделены только для классических методов, но такое же разделение применимо и к другим основным группам.

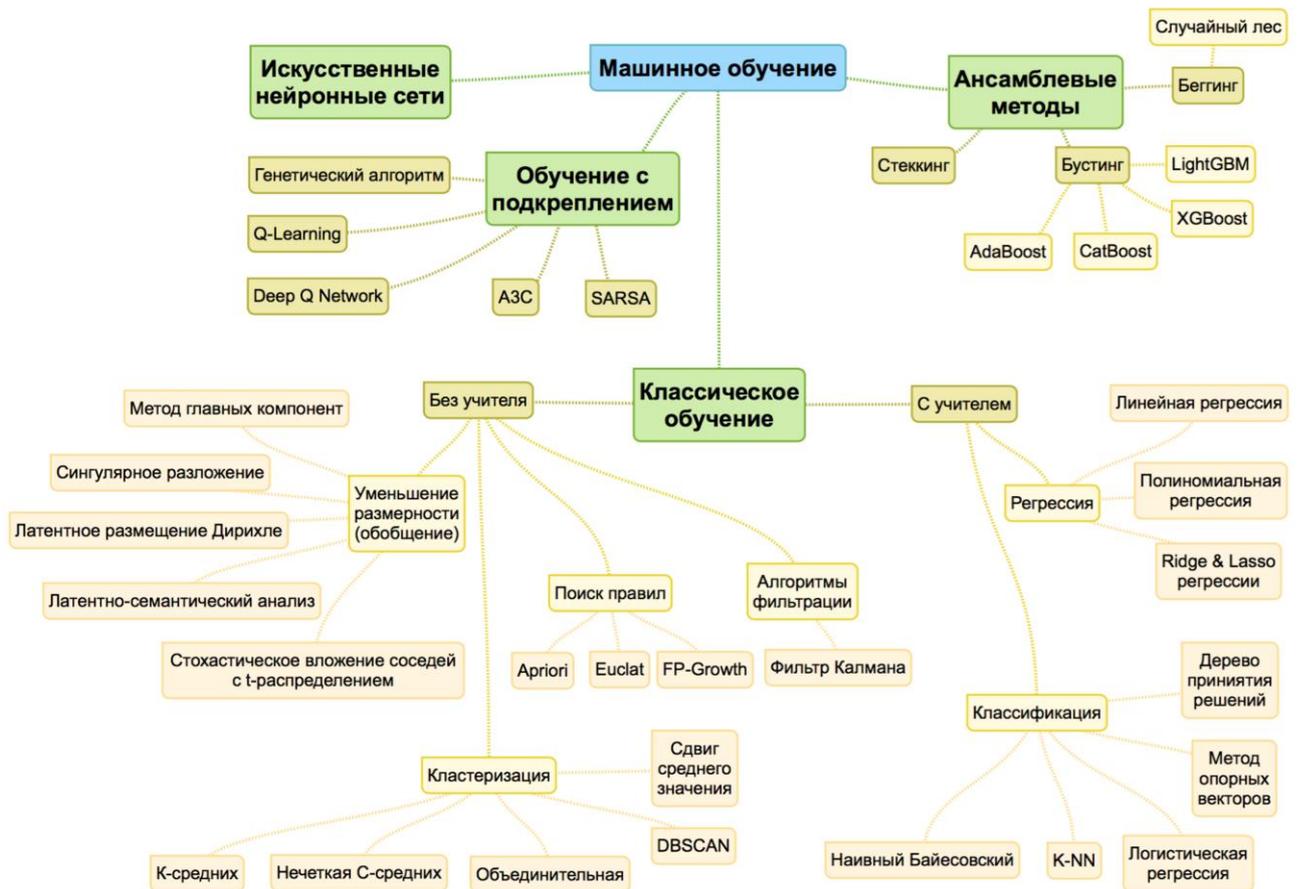


Рис. 1.6 – Классификация методов машинного обучения

Далее будет приведено описание применения тех методов машинного обучения, которые используются для управления ЭЭС.

Деревья принятия решений (Decision tree)

В задачах управления ЭЭС деревья принятия решений, как правило, используются для выявления опасных, аварийных и предаварийных режимов. Например, в работе [81] используются оптимизированные деревья принятия решений для предсказания аварий на линиях электропередачи. Оптимизация заключалась в том, что использовались априорно заданные корреляции в исходных данных. Зависимые друг от друга данные заменялись на один параметр, тем самым, уменьшая размер дерева и исключая переобучение на зависимых друг от друга данных. В работе [82] деревья принятия решений применяются для диагностики отказов в работе солнечной электростанции, подключенной к внешней электрической сети. Также данный метод используется для выявления коммерческих потерь в распределительных сетях [83]. Деревья принятия решений используются и для предварительной классификации входных данных в задачах прогнозирования, например, прогнозирования цен на электроэнергию в Smart Grid [85, 86].

Метод опорных векторов (Support Vector Machine)

В задачах для энергосистем метод опорных векторов рассматривается для решения различных задач классификации данных и детектирования определенных ситуаций. Так, в [98] выявляются и классифицируются отказы в электрической сети, а в [95] метод используется для предсказания каскадных аварий. В [96] выявляются ситуации разделения на изолированно работающие острова электрической сети, использующей распределенную генерацию. В работе [97] выявляются кибернетические атаки на систему управления интеллектуальной сети. В работах [99, 100] выполняется классификация погоды для последующего прогнозирования мощности генерации солнечной электростанции.

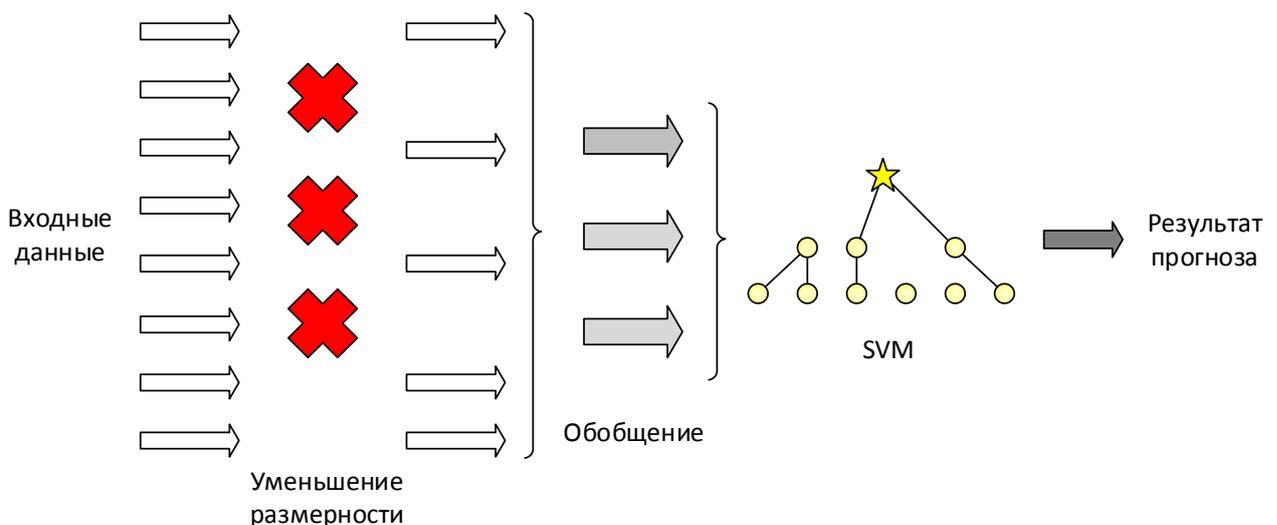


Рис. 1.7 – Применения классификации и уменьшения размерности в задачах прогнозирования.

Методы машинного обучения, используемые для классификации, применяются также в задачах прогнозирования для промежуточной классификации входных данных. Типовая схема применения таких методов показана на Рис. 1.7.

Метод главных компонент (Principal Component Analysis)

Исходные данные, применяющиеся для автоматического управления ЭЭС, часто содержат явно или косвенно зависимые друг от друга параметры. Для уменьшения объема входных данных используются методы уменьшения размерности, одним из которых и, пожалуй, наиболее часто применяемым, является метод главных компонент. Данный метод аппроксимирует n -мерное облако наблюдений до эллипсоида (тоже n -мерного), полуоси которого и являются главными компонентами набора данных. При проекции на такие оси (снижении размерности) сохраняется наибольшее количество информации. Пример применения метода главных компонент в задаче прогнозирования приведен в [86].

Регрессия

Регрессия применяется для прогнозирования изменения параметров системы на основе трендов их изменения. Простые линейные или полиномиальные регрессии не дают удовлетворительного результата для прогнозирования изменения параметров ЭЭС. При этом есть работы [101], в которых для прогнозирования применяются множественные регрессии на разном масштабе времени.

Регрессия на машинах опорных векторов (Support Vector Regression)

В прогнозировании параметров ЭЭС применяются более эффективные методы регрессии, такие как регрессии на машинах опорных векторов. Хотя SVR построены на моделях SVM, они имеют отличия. Основное отличие заключается в том, что понимается под разделяющей гиперплоскостью. В SVM – это плоскость, разделяющая классы данных. В SVR – это направление, позволяющее предсказать непрерывное значение.

Исследования применения регрессии на машинах опорных векторов в электроэнергетике представлено в ряде работ. Так в [102] SVR используется для прогнозирования выработки ветровой электростанции. В [104] SVR используется для прогнозирования нагрузки, а в [103] нагрузка прогнозируется с помощью SVR совместно с алгоритмом дифференциальной эволюции (стохастический алгоритм оптимизации).

Метод релевантных векторов (Relevance Vector Machine)

Метод релевантных векторов – это байесовская модификация метода опорных векторов. Метод имеет идентичную функциональную форму методу опорных векторов, но использует вероятностную классификацию.

Метод релевантных векторов применяется для прогнозирования электрической нагрузки [105, 106], мощности солнечных электростанций [107], цен на электроэнергию для малой генерации в условиях Smart Grid [108], а также для прогнозирования ветра для оптимизации работы ветровых электростанций [109].

В сравнении с методом опорных векторов метод релевантных векторов имеет сравнимую, но незначительно лучшую точность. Количество ядер в решении при этом у SVR значительно меньше и RVM не нуждается в настройке параметра регуляризации на этапе обучения. Однако, этот метод имеет и недостаток: фаза обучения RVM включает в себя нелинейный процесс оптимизации, что значительно замедляет обучение.

Случайный лес (Random Forest)

С развитием компьютерной техники и возможности распараллеливать вычислительный процесс получили развитие так называемые ансамблевые методы машинного обучения, использующие несколько экземпляров простых методов машинного обучения. Наиболее популярный ансамблевый алгоритм машинного обучения, применяемый в энергетике – это «случайный лес». Этот алгоритм использует ансамбль, объединенный по принципу «бэггинг», когда один алгоритм обучается много раз на случайных выборках из исходных данных. Результаты обучения каждого отдельного алгоритма усредняются для получения итогового решения.

Алгоритм с использованием метода случайных подпространств впервые предложен Тин Кам Хо [87] и является способом реализации подхода "стохастической дискриминации" Кляйнберга [89]. Дальнейшее развитие алгоритм получил в работе Бреймана [88]. Алгоритм случайного леса применяется для задач классификации, регрессии и кластеризации. Основная идея заключается в использовании большого ансамбля решающих деревьев, каждое из которых само по себе даёт достаточно невысокое качество классификации, но за счёт их большого количества результат получается удовлетворительным.

В работе [80] – случайный лес, SVM и персептрон используются для выявления и предупреждения аварийных событий в энергосистеме. Случайный лес используется также для оценки режимной надежности [90, 91]. В работе [92] он применяется для оценки динамической режимной надежности. Также данный метод

машинного обучения находит применения для выявления кибератак на систему управления Smart Grid [84].

Бустинг (Boosting)

Если в алгоритме Случайного леса модели объединяются в ансамбль параллельно, то в бустинге используется последовательное применение простых моделей в ансамбле. Хороший обзор по методам бустинга приведен в [94]. В 1988 году Кернс и Валиант [110] были первыми, кто поставил вопрос о том, может ли “слабый” алгоритм обучения, который работает чуть лучше, чем случайное угадывание, быть “усилен” (boost), путем объединения в группу последовательно работающих алгоритмов.

Дальнейшее развитие метод бустинга получил в [93], где был предложен алгоритм AdaBoost (сокращение от Adaptive Boosting). Этот алгоритм может использоваться в сочетании с несколькими алгоритмами классификации для улучшения их эффективности. AdaBoost является адаптивным в том смысле, что каждый следующий ансамбль классификаторов строится по объектам, неверно классифицированным предыдущими ансамблями. AdaBoost чувствителен к шуму в данных и выбросам, но он менее подвержен переобучению по сравнению с другими алгоритмами бустинга. При этом, алгоритм Adaboost оказывается неустойчив на данных с резкими выбросами. Решением данной проблемы стал градиентный бустинг (Gradient Boosting Machine) [110], обобщающий подход примененный в AdaBoost, представляя его, как оптимизационную задачу в функциональном пространстве.

В электроэнергетике градиентный бустинг с применением алгоритмов регрессии часто применяется для прогнозирования электрических режимов и цен на электроэнергию. Например, в [114] применяется регрессия на машинах опорных векторов с использованием градиентного бустинга для прогнозирования нагрузки в Smart Grid. Также применяется регрессия с использованием деревьев принятия решений. Хотя деревья принятия решений в первую очередь разрабатывались для задач классификации, они нашли применение и в задачах регрессии. Непрерывное решение при этом дискретизируется деревьями принятия решений. Качество регрессии может быть улучшено применением на верхнем уровне алгоритмов бустинга. Так в работе [115] было проведено сравнение алгоритмов случайного леса и градиентного бустинга деревьев регрессии (Gradient Boosted Regression Tree) для задачи прогнозирования нагрузки в электрической сети и последний показал лучший результат. Градиентный бустинг с применением деревьев принятия решений применяется также для моделирования потребления в здании [112] и для прогнозирования мощности генерации солнечных электростанций [116]. Также алгоритмы

бустинга совместно с деревьями принятия решений находят и более традиционное применение в задачах классификации, например, – для секционирования электрической сети [113].

Условные случайные поля (Conditional Random Fields)

Условные случайные поля (CRF) – класс методов статистического моделирования, применяемых в распознавании паттернов и машинном обучении [117]. Данные методы относятся к методам моделирования последовательностей и используются для выделения и предсказания в них определенных структурных особенностей (паттернов). Если дискретные классификаторы выделяют паттерны из единичного «среза» исходных данных, то CRF используют информацию нескольких «срезов» данных в последовательности.

Методы CRF для непрерывных значений нашли применение в энергетике для прогнозирования нагрузки [118]. Условные случайные поля представляют собой ненаправленный граф, узлы которого соответствуют вероятности определенного состояния системы $Y = (y_1, y_2, \dots, y_n)$, а ветви – условия изменения вероятностей смежных узлов, использующие вектор входных данных $X = (x_1, x_2, \dots, x_n)$. Для метода непрерывных случайных полей (Continuous Conditional Random Fields) условная вероятность $P(Y|X)$ вычисляется с учетом функциональной зависимости выходного значения CCRF от вектора входных величин $H(y_i, X)$ и зависимости между выходными величинами $H(y_i, y_j, X)$. Подробней о CCRF в [119].

Кластеризация

Методы машинного обучения, применяемые для кластеризации, как правило, являются вспомогательными в задачах оптимального управления ЭЭС. Например, в [A5] для кластеризации автором диссертационной работы применяются алгоритмы раскладки графа на плоскости совместно с применением модифицированного нечеткого алгоритма с-средних. Кластеризация схемы ЭЭС с помощью данной методики позволяет быстро выделить слабые связи в сети и может служить хорошим начальным приближением для поиска траекторий утяжеления в задаче анализа устойчивости ЭЭС.

Фильтр Калмана

В электроэнергетике применяются различные методы фильтрации исходных данных, в том числе для анализа качества напряжения и доли высших гармоник. В

данной работе больший интерес представляет фильтр Калмана [120, 121], применяющийся для динамического оценивания состояния. Термин «динамическое оценивание состояния» появился в 1970-х годах, когда фильтр Калмана впервые был применен для оценивания состояния [122].

Имеются попытки применения различных модификаций фильтра Калмана для задачи оценивания состояния. Например, в работе [125] применяется расширенный фильтр Калмана (Extended Kalman filter) для динамического оценивания состояния режима генератора, работающего на шины бесконечной мощности. В [126] фильтр Калмана применяется для оценивания состояния и прогнозирования электрических режимов. В работах [123, 124] расширенный фильтр Калмана (ЕКФ) применяется для оценивания состояния уже достаточно сложных ЭЭС (около 30 узлов). ЕКФ по структуре похож на свою линейную версию, но отличается тем, что уравнения динамики и наблюдений содержат нелинейные функции от фазовых координат. Это отличие предполагает наличие перекрестных связей между фазовыми координатами. При использовании ЕКФ необходимо на каждом шаге итераций вычислять Якобиан целевой функции, что значительно повышает вычислительную сложность. Кроме того, использование сильно нелинейной модели динамической системы приводит к очень плохой обусловленности задачи, и если модель системы содержит значительные нелинейности, то ЕКФ будет давать существенную погрешность.

Есть также специальные реализации алгоритма ЕКФ, обеспечивающие его большую робастность. В [127] предложен алгоритм динамического оценивания состояния, основанный на ЕКФ и использующий экспоненциальную весовую функцию при вычислении ошибки фильтра Калмана.

Более эффективная для оценивания состояния реализация фильтра Калмана – это сигма-точечный фильтр Калмана (Unscented Kalman Filter), основанный на одноименном ансцентном преобразовании. Данный метод устраняет необходимость явного вычисления Якобиана [130, 121, 129].

Одним из наиболее показательных примеров использования сигма-точечного фильтра Калмана для задач управления ЭЭС является его применение для динамического оценивания состояния [128]. В этой работе авторы обосновывают эффективность применения UKF по сравнению с ЕКФ для данной задачи.

Генетические алгоритмы и другие био-подобные методы

Генетические алгоритмы (ГА) относятся к алгоритмам машинного обучения с подкреплением. ГА – это эвристические алгоритмы, используемые для решения задач оптимизации и моделирования путём случайного подбора, комбинирования и

вариации искомым параметров с использованием механизмов, аналогичных естественному отбору в природе. Использование ГА для решения задач оптимизации было предложено еще в 1960-х Рехенбергом и Швифелем. С тех пор по данной тематике опубликовано множество работ, в том числе и в области энергетики.

Согласно исследованиям [131], достоинства ГА заключаются в следующем:

- Возможно использовать большое количество управляющих переменных.
- Можно оптимизировать функции с множеством локальных минимумов, не «застревая» в них.
- Не требуется знания физической модели исследуемого процесса, формы поверхности, образуемой целевой функцией или ее градиента. Достаточно уметь вычислять значение целевой функции в выбранных точках пространства управляющих переменных.

Однако, указанные преимущества не перевешивают недостатков ГА, таких, как:

- Большое количество итерации процесса поиска оптимума с использованием ГА.
- Неэффективность для гладких унимодальных целевых функций.
- Проблемы при оптимизации эпистатических функций.

Хотя основным достоинством ГА, является его способность преодолеть так называемое проклятие размерности и использовать большое количество управляющих переменных, при решении реальных задач ГА сталкивается с проблемой эпистаза, когда проявление одного гена находится под влиянием другого гена. В каждой нетривиальной проблеме оптимизации должна быть хотя бы небольшая степень эпистазиса, в противном случае проблема будет тривиальной. Решение же тривиальной проблемы методом ГА будет, как правило, нецелесообразным. С другой стороны, если функция является эпистатической, ГА не может обработать ее должным образом и в большинстве случаев не может найти правильный ответ [132].

Также следует упомянуть и другие био-подобные методы. Количество публикаций по использованию таких методов, в том числе в энергетике, достаточно велико (Рис. 1.8), однако следует отметить, что, пожалуй, единственным преимуществом данных методов является их интуитивная наглядность. С другой стороны, их применение, как правило ограничено достаточно локальными задачами в рамках небольших моделей или в составе других классических или нейросетевых алгоритмов для предварительной подготовки исходных данных.



Рис. 1.8 – Публикации по использованию био-подобных методов в технических науках.

Обучение с подкреплением (Reinforcement Learning)

Метод обучения с подкреплением получил значительное развитие, особенно с развитием глубокого обучения ИНС. На Рис. 1.9 представлены различные модификации метода обучения с подкреплением.

Обучение с подкреплением является одной из наиболее заманчивых технологий машинного обучения. Многими исследователями озвучивается идея, что для обучения с использованием технологии RL достаточно создать среду, обеспечивающую адекватную реакцию, и система сама проиграет множество ситуаций во взаимодействии с этой средой, тем самым обучаясь максимизировать свою целевую функцию.



Рис. 1.9 – Различные модификации метода обучения с подкреплением.

Большое количество исследований применения RL есть и в энергетике [169]. В основном они касаются управления какой-то ограниченной электрической системой (установкой, зданием, распределительной сетью (micro-grid). Так, например, в работе [134] приводится описание и обзор применения обучения с подкреплением для управления энергоснабжением здания. В статье [136] используется RL с использованием мини-батчей для реализации управления энергопотреблением дома, которая может автономно принимать решений о продаже или хранении избыточной энергии в “умном” доме. Статья [137] использует глубокое Q-обучение и глубокий градиент по стратегии (Deep Policy Gradient) для принятия решений, как на уровне здания, так и на уровне распределительной сети.

В статье [138] предлагается система динамического управления энергопотреблением в распределительной сети, сочетающая эволюционное адаптивное динамическое программирование с моделью RL. Планирование и эксплуатация накопления энергии в микросетях - сложная проблема. В работах [139, 140] RL применяется для управления процессом накопления и выдачей энергии в микросети, чтобы максимизировать собственное потребление энергии из локальной фотоэлектрической системы и минимизировать затраты на электроэнергию получаемую из энергосистемы. В статье [141] предложена стратегия RL для управления периодами зарядки и разрядки различных систем накопления энергии.

Большое количество работ посвящено экономическим вопросам взаимодействия «умных» потребителей, микро-сетей, а также традиционных электрических сетей. В статье [142] предложена новая структура экономического взаимодействия нескольких взаимосвязанных микро-сетей. В данной работе, используется RL для выбора оптимальной стратегии торговли электроэнергией на независимом рынке. В работе [143] рассмотрены проблемы неполноты информации о текущем потреблении в микро-сети и разработаны алгоритмы RL, позволяющие каждому поставщику услуг и каждому клиенту оптимизировать свою стратегию без априорной информации о режиме микросети. В статье [144] применяется динамическое программирование на основе Q-обучения в схемах реагирования по требованию для поддержки принятия решений заказчиком в режиме реального времени.

Обучение с подкреплением находит свое применение и в исследованиях, посвященных противоаварийному управлению. В [145] глубокое RL используется для принятия решений по стратегиям противоаварийного управления. В частности, сверточная ИНС (Convolutional Neural Network) используется для обобщения характеристик режима ЭЭС во время переходного процесса, а модель двойного

Q-обучения и модель дуэльного Q-обучения используются для выработки стратегии управления.

Оптимизм в применении обучения с подкреплением и особенно глубоких нейронных сетей, обучающихся с использованием RL, особенно проявился после успехов AlphaGo, алгоритм которого обучался игре в Го, играя множество партий сам с собой. В реальности не все так радужно с RL. Как утверждается в [133] 70% задач управления на настоящее время не могут быть эффективно решены обучением с подкреплением. В чем же проблемы использования обучения с подкреплением в реальных инженерных задачах:

- Обучение с подкреплением предполагает существование функции вознаграждения. Обычно она или есть изначально, или настраивается вручную в автономном режиме и остаётся неизменной во время обучения. Для правильной работы RL функция вознаграждения должна охватывать в точности то, что нужно для оптимального управления. При этом RL очень склонен к переобучению (overfit). При этом система склонна терять дальнейшую обучаемость.
- Для обучения алгоритма RL требуется адекватная среда, эмулирующая реальную исследуемую систему. Если детерминированная модель, эмулирующая среду, действительно адекватна, то встает вопрос в необходимости применения RL вместо управления с помощью этой модели. Если в качестве среды используются ретроспективные данные, то (по крайней мере для энергетики), их глубина ограничена и, кроме того, они не отражают реакцию среды на действия агента.
- Размер решаемой задачи, которая по силам RL, достаточно небольшой. При росте размерности решаемой задачи рост вычислений – экспоненциальный [135].
- RL очень чувствителен как к инициализации, так и к динамике обучения.

Таким образом, можно сделать вывод, что в настоящий момент применение RL для управления ЭЭС ограничено достаточно небольшими локальными системами. При этом в дальней перспективе данная технология выглядит перспективной и требует дальнейших исследований.

1.4 Искусственные нейронные сети и их применение для задач управления режимами ЭЭС

Искусственные нейронные сети (ИНС) – это модели обработки информации, создание которых было вдохновлено структурой нейронных сетей в мозге животных. При этом нельзя говорить о сколько-нибудь адекватной аналогии искусственных нейронных сетей реальному мозгу. ИНС – это математическая модель, позволяющая решать задачи, решение которых детерминированными методами сложно или невозможно в связи с недостаточностью данных и отсутствием модели, учитывающей все влияющие факторы. Одним из основных преимуществ ИНС является возможность решения задач большого объема и достаточно простая масштабируемая процедура обучения модели.

Хорошие обзоры различных моделей нейронных сетей представлены в [146 – 148]. Далее кратко опишем основные архитектуры нейронных сетей с использованием условных обозначений (Таблица 1.2) взятых из [146].

Таблица 1.2. Условные обозначения для описания архитектуры ИНС

 Входная ячейка	 Рекуррентная ячейка
 Двухнаправленные входные нейроны	 Ячейка с памятью
 Входная ячейка с дополнительным шумом	 Управляемые ячейки с памятью
 Скрытая ячейка	 Ядерные ячейки
 Вероятностная скрытая ячейка	 Свертка или пулинг (субдискретизация)
 Спайковая (импульсная) скрытая ячейка	 Выходная ячейка
	 Соответствие входа и выхода

Наиболее простыми вариантами архитектуры ИНС являются **сети прямого распространения** (Рис. 1.10). Данные модели получили распространение благодаря своей простоте. Имеется значительное количество работ, в которых данные архитектуры ИНС применяются для задач оценивания состояния и прогнозирования режимов ЭЭС. Результатом работы данной сети является вектор выходов, полученный только на основе входов. Обучаются данные сети методом обратного распространения ошибки, передавая в алгоритм обучения векторы входных и ожидаемых значений.

Имеются также модификации сетей прямого распространения, в которых связи с нейронами скрытого слоя заданы случайным образом при инициализации ИНС (Рис. 1.11). Такие ИНС называются **экстремально обучаемые машины** (Extreme learning machines, ELM). Как утверждают авторы данной методики, ELM обладают хорошей эффективностью и обучаются в тысячи раз быстрее чем сети, использующие обратное распространение ошибки [151]. Используются ELM для классификации, регрессии, кластеризации, разреженной аппроксимации, сжатия и обучения признакам. Параметры скрытых узлов ELM (включая их веса) не настраиваются в процессе обучения. В результате скрытые слои ELM представляют собой сложную нелинейную модель. Выходной слой представляет собой линейную модель, обучение которой происходит практически за один шаг.

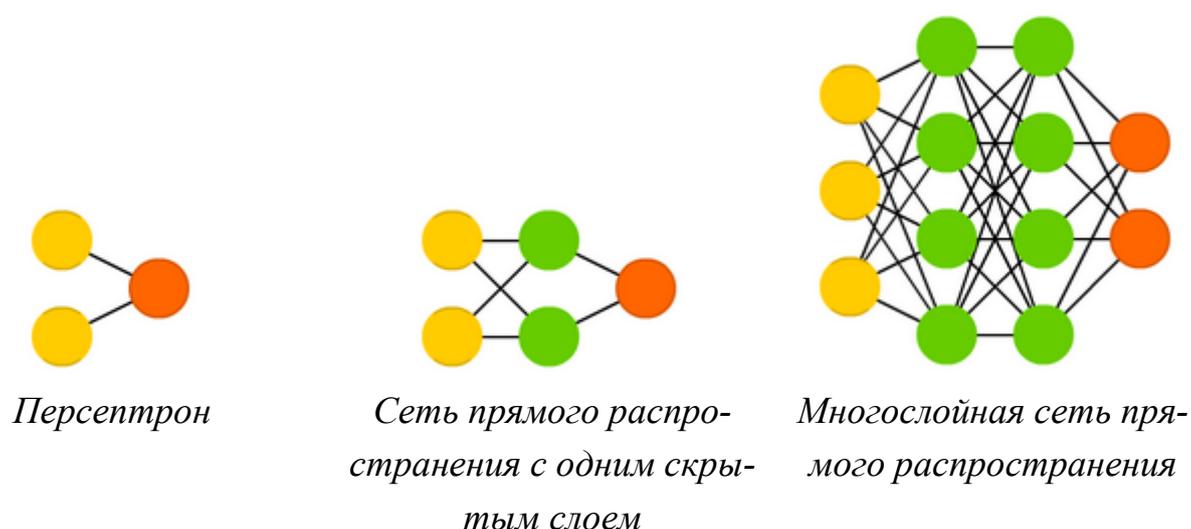


Рис. 1.10 – Сети прямого распространения.

В задачах управления ЭЭС экстремально обучаемые машины также находят применение, хотя их эффективность случайным образом зависит от начальной инициализации ELM. В работе [152], посвященной выявлению кибератак на систему управления интеллектуальными сетями, используется алгоритм имитации поведения роя пчел для начальной инициализации сети ELM. В данной работе эффективность применения ELM в большей степени зависит именно от вспомогательного алгоритма инициализации ИНС. Есть попытки использования ELM и в задачах прогнозирования [153]. При этом начальная настройка ELM также осуществляется био-подобными эвристическими алгоритмами.

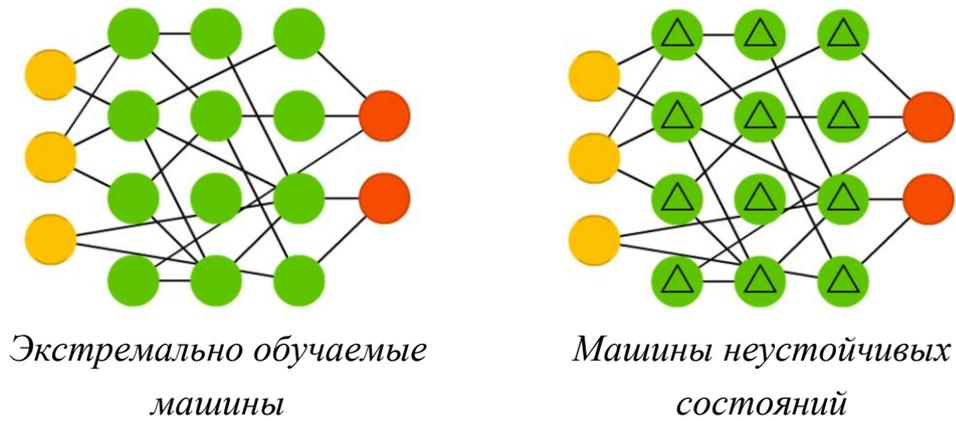


Рис. 1.11 – Сети прямого распространения со случайными связями.

Машины неустойчивых состояний (Liquid state machines, LSM) подобны по архитектуре ELM, но отличаются тем, что в них используются пороговые функции активации, и каждый нейрон также является накопительным блоком памяти. Когда состояние нейрона обновляется, значение рассчитывается не как сумма его соседей, а складывается с самим собой. Как только порог превышен, энергия освобождается и нейрон посылает импульс другим нейронам [154]. В энергетике данные ИНС не используются.

Следующим классом архитектур нейронных сетей являются **полносвязанные сети** (Рис. 1.12). Развитие полносвязанных сетей началось от вероятностных моделей машинного обучения, называемых цепями Маркова. Хотя цепи Маркова не относятся к нейросетевым моделям, их можно представить, как один слой двунаправленных входных нейронов, в котором все нейроны связаны между собой (есть реализации неполносвязанных цепей Маркова). Цепь Маркова представляет собой граф, узлам которого соответствуют состояния системы, а ребрам – вероятности перехода между состояниями. Особенностью цепей Маркова является то, что состояние сети зависит только от текущего значения входов.

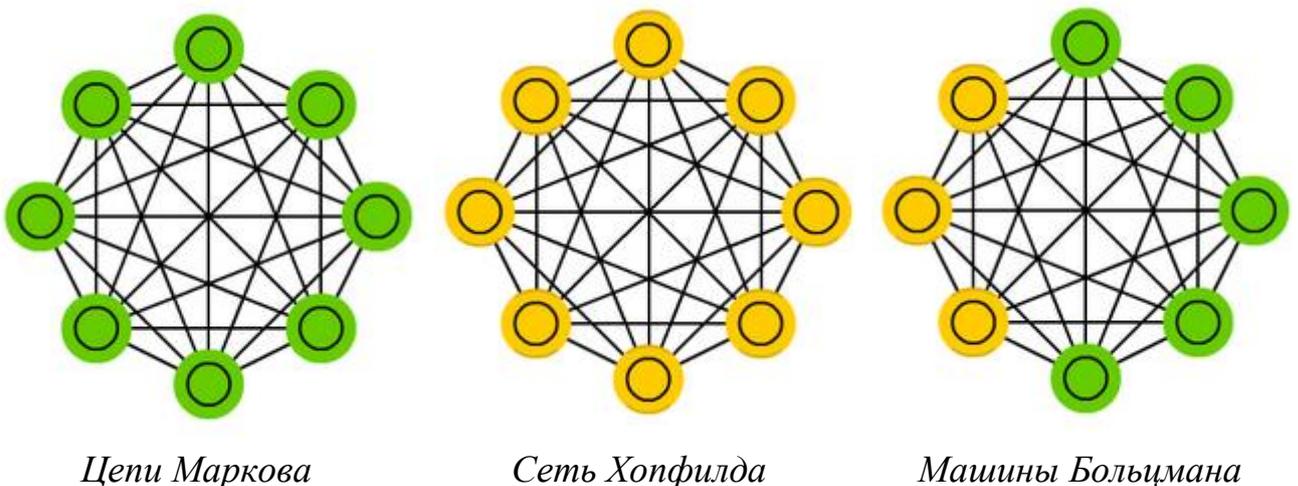


Рис. 1.12 – Полносвязанные сети.

В сетях Хопфилда каждый нейрон выступает в трех качествах: входным до обучения, скрытым во время обучения и выходным после. Матрица весов подбирается таким образом, чтобы все «запомненные» вектора являлись бы для нее собственными. Однажды обученная одному или нескольким образом система будет сходиться к одному из известных ей образов, потому что только одно из этих состояний является стационарным.

Машина Больцмана (Boltzmann machines, BM) отличается от сети Хопфилда тем, что она является стохастической (как и цепи Маркова) нейронной сетью, а также некоторые нейроны являются только скрытыми. Обучение данных ИНС производится методом обратного распространения ошибки или с помощью алгоритма *contrastive divergence* (когда градиент вычисляется при помощи марковской цепи). В процессе обучения активация нейронов регулируется значением общей температуры, при понижении которой сокращается и энергия нейронов, влияющая на активность флуктуаций состояний нейронов. Сокращение энергии вызывает стабилизацию нейронов, что похоже на алгоритм имитации отжига.

Ограниченная машина Больцмана (Restricted Boltzmann machine, RBM) создана модификацией обычной машины Больцмана, в которой нейроны разделили на видимые и скрытые, а связи при этом допустимы только между нейронами разного типа, таким способом ограничив связи (Рис. 1.13 – Ограниченные машины Больцмана). Особенность этой модели в том, что при данном состоянии нейронов одной группы, состояния нейронов другой группы будут независимы друг от друга.

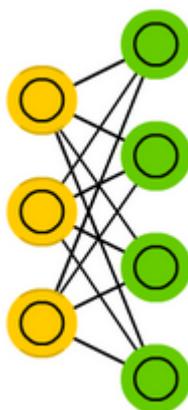


Рис. 1.13 – Ограниченные машины Больцмана.

Для задач классификации часто применяют архитектуру ИНС, называемую **автоэнкодерами** (АЕ).

Основная идея автоэнкодеров — уменьшение размерности решаемой задачи от слоя к слою в процессе кодирования и развертка сжатой информации опять до

прежнего размера. В результате в процессе обучения автоэнкодера на внутренних слоях выделяются характерные признаки. Обучаются данные сети методом обратного распространения ошибки, подавая входные данные и задавая ошибку равной разнице между входом и выходом. Применительно к задачам управления ЭЭС автоэнкодеры используются для выявления аварийных и предаварийных ситуаций.

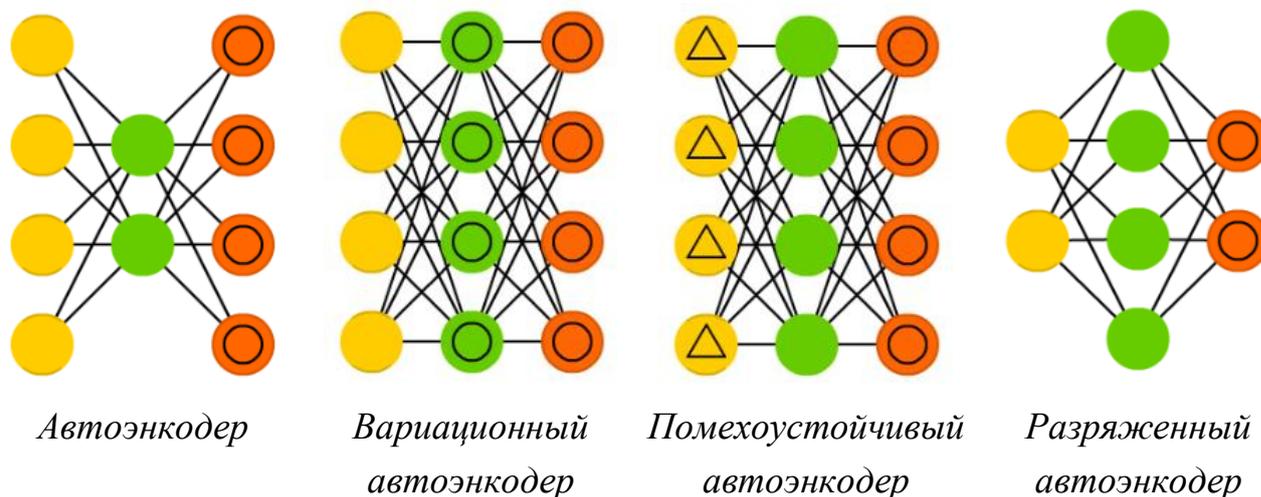


Рис. 1.14 – Вариационные автоэнкодеры.

Помехоустойчивый автоэнкодер (Denoising autoencoders, DAE) позволяет концентрироваться на самых характерных деталях входных данных. Это достигается за счет добавления шума к входным данным в процессе обучения.

Вариационные автоэнкодеры (Variational autoencoders, VAE) основаны на той же архитектуре, что и обычные автоэнкодеры, но используют Байесовские методы для вычисления вероятностного распределения.

Разреженные автоэнкодеры используются для выявления мелких деталей в исходных данных. Для этого их архитектура обратна архитектуре обычных автоэнкодеров. Скрытые слои у них больше чем входные и выходные. Чтобы избежать ситуации, когда сеть будет обучаться выдавать на выход ровно то, что ей подается на вход, обучение разреженных автоэнкодеров происходит по-другому. В минимизируемую в процессе обучения целевую функцию добавляются штрафы за количество активированных нейронов на скрытых слоях.

Имеются попытки применения автоэнкодеров и для задач оценивания состояния и прогнозирования электрических режимов. Так в работе [184] автоэнкодеры применяются для построения характерных профилей нагрузки. Применение автоэнкодеров для задачи оценивания состояния и прогнозирования, как основного ал-

горитма машинного обучения [185], достаточно спорно, так как эта модель позволяет выявить характерные признаки, но режим при этом может значительно отличаться от реального. Однако применение автоэнкодеров, в качестве вспомогательного алгоритма, работающего, например, совместно с рекуррентными ИНС, достаточно эффективно [186].

Глубокие сети доверия (Deep belief networks, DBN) представляют собой композицию нескольких RBM или VAE. Такие сети показали себя эффективно обучаемыми одна за другой, когда каждая сеть должна научиться кодировать предыдущую.

Имеются примеры применения DBN, использующих в своем составе ограниченные машины Больцмана, для задач прогнозирования нагрузки в электрических сетях [187, 188]. При этом авторы сравнивают только методы обучения ИНС, но не сравнивают применение архитектуры DBN с другими архитектурами ИНС.

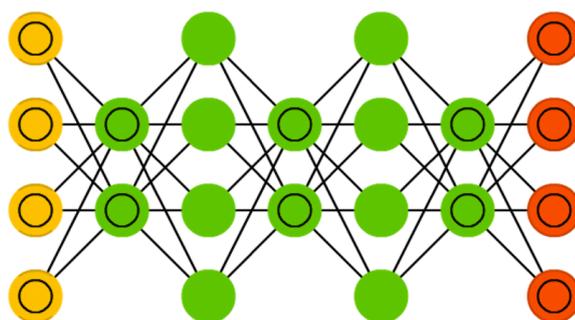


Рис. 1.15 – Глубокие сети доверия.

Сверточные сети (Convolutional neural networks, CNN) – это широкий класс архитектур искусственных нейронных сетей, основная идея которых состоит в использовании одних и тех же частей нейронной сети для обработки разных небольших локальных участков входных данных. Идея сверточной сети мотивирована идеями о строении зрительной коры головного мозга. Как и в мозге при анализе изображения, в сверточной сети происходит сканирование изображения небольшими участками.

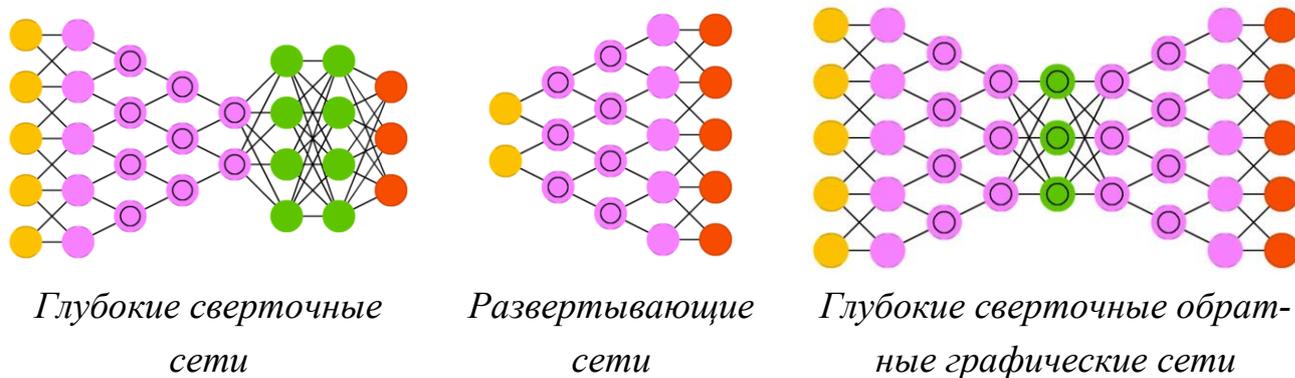


Рис. 1.16 – Сверточные нейронные сети.

Основной структурной единицей CNN является сверточный слой, однако есть также так называемые слои объединения (pooling layers). Объединение — это способ уменьшить размерность получаемых данных, например, из квадратной матрицы, соответствующей части данных предыдущего слоя, выбирается одно наиболее характерное значение. На практике CNN дополняются на выходе многослойными сетями прямого распространения (FFNN) для дальнейшей обработки данных. Такие сети называются глубокими сверточными сетями (DCNN). Варианты архитектур ИНС, использующих идеи сверточных сетей, представлены на Рис. 1.16.

Есть варианты обратных сверточных сетей, называющиеся **развёртывающие нейронные сети** (deconvolutional networks, DN) [149]. Данные сети позволяют из имеющихся признаков построить графический образ оригинальной размерности. Вместо слоев объединения, которые часто встречаются в CNN, здесь присутствуют аналогичные обратные операции, обычно использующие интерполяцию или экстраполяцию. Обычно развёртывающие нейронные сети объединяются со сверточными, как это сделано в **глубоких сверточных обратных графических сетях** (Deep convolutional inverse graphics networks, DCIGN), являющихся по сути вариационными автоэнкодерами со сверточными и развёртывающими сетями в качестве кодирующей и декодирующей частей, соответственно.

Основное использование сверточных сетей — это обработка изображений и иногда аудио и других потоковых данных. Типичным способом применения CNN является классификация образов из исходных данных. Есть примеры исследований по применению данной архитектуры и для задач энергетике. Например, в [150] сверточные сети используются для прогнозирования нагрузки. Однако, применение их не дает лучшего результата, чем применение SVR.

Генеративные состязательные сети (Generative adversarial networks, GAN) принадлежат к классу порождающих моделей (Рис. 1.17) [155, 148] с неявно выраженной плотностью вероятности $p(x, y)$.

В основе GAN (Рис. 1.18) лежат две соревнующиеся друг с другом сети (чаще это сети прямого распространения или сверточные), где одна из сетей генерирует данные (“генератор”), а вторая — отличает порожденные данные от генерируемых (“дискриминатор”). То, насколько точно дискриминатор определяет сгенерированные данные или они настоящие, служит для оценки ошибок генератора. Таким образом, происходит соревнование между дискриминатором и генератором. Первый учится лучше отличать реальные данные от сгенерированных, а генератор стремится стать менее предсказуемым для дискриминатора. GAN достаточно сложно обучить, так как задача здесь — не просто обучить две сети, но и соблюдать

необходимый баланс между ними. Если одна из частей (генератор или дискриминатор) станет намного лучше другой, то GAN никогда не будет сходиться.



Рис. 1.17 – Порождающие модели нейронных сетей.

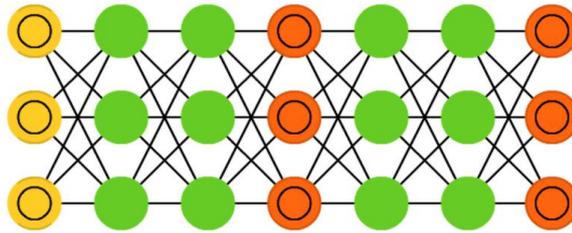
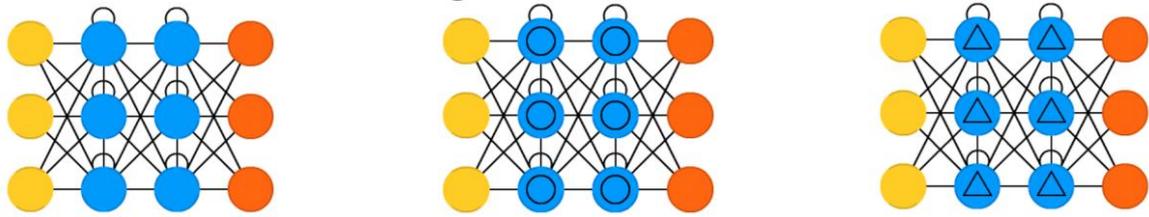


Рис. 1.18 – Генеративные состязательные сети.

Генеративные сети находят лишь ограниченное применение в исследованиях по применению ИНС для управления электрическими сетями [156], хотя могли бы применяться для выявления аварийных событий.

Рекуррентные нейронные сети (Recurrent neural networks, RNN) по сути представляют собой сети прямого распространения, но со смещением во времени, когда нейроны скрытых слоев получают информацию не только от предыдущего слоя, но и от самих себя в результате предыдущего прохода (Рис. 1.19). Рекуррентные сети эффективно используются для прогнозирования последовательностей, в том числе в энергетике. У классических RNN есть большая проблема исчезающего (или взрывного) градиента: в зависимости от используемой функции активации информация со временем теряется, также, как и в очень глубоких сетях прямого распространения.



Рекуррентные нейронные сети

Долгая краткосрочная память (LSTM)

Управляемые рекуррентные модули (GRU)

Рис. 1.19 – Рекуррентные ИНС.

Для решения проблемы взрывных градиентов разработаны специальные архитектуры рекуррентных сетей. Одна из эффективных архитектур – **долгая краткосрочная память** (Long short term memory, LSTM) в которой информация о прошлых моментах времени исследуемой последовательности передается не напрямую, а с использованием фильтров: входной фильтр, выходной фильтр и фильтр забывания. Использование фильтров позволяет регулировать поток информации от предыдущих шагов. Архитектура LSTM была предложена еще в середине 1990-х годов [165]. Наиболее часто используемая архитектура LSTM описана в работе Герса Шмидхубера 2000 года [166]. Вместе с тем, подходы, основанные на глубоком обучении, применительно для задач прогнозирования, получили популярность достаточно недавно.

LSTM могут обучаться действительно сложным последовательностям. Сравнение различных модификаций LSTM приведено в [157]. Архитектура LSTM требует значительных ресурсов для своего обучения. При этом в [157] показано, что для эффективной работы LSTM достаточно двух фильтров (входного и забывающего). Для ускорения обучения сети LSTM разработана упрощенная архитектура, в которой используется идея совмещения выходного и забывающего фильтра, а скрытое состояние совмещено со значением памяти. Данная архитектура называется **управляемые рекуррентные модули** (Gated recurrent units, GRU).

Рекуррентные нейронные сети, и в частности LSTM, позволили ИНС избавиться от проблемы фиксированного размера входных данных. Следующим шагом развития ИНС можно рассматривать **нейронные машины Тьюринга** (Neural Turing machines, NMT) (Рис. 1.20). Название «нейронные машины Тьюринга» взято авторами [164] за счет аналогии NMT с классической машиной Тьюринга. NMT можно определить как модификацию LSTM использующую внешний блок памяти. Это позволяет объединить производительность и неизменность обычного цифрового хранилища данных с производительностью и выразительными возможностями нейронной сети.

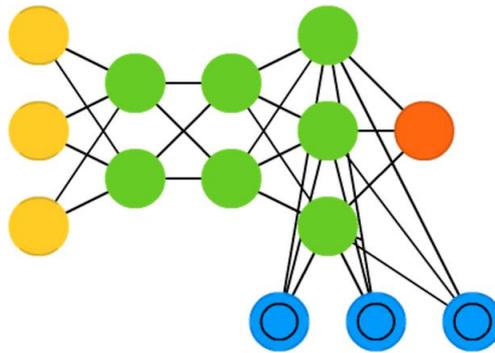


Рис. 1.20 – Нейронные машины Тьюринга.

Разработчиками архитектуры NMT было проведено сравнение работы NMT с оригинальной архитектурой LSTM. Результаты приведенных тестов показали, что NMT в отдельных случаях могут превзойти LSTM и обучиться более обобщенным алгоритмам, чем LSTM, и работать на более длинных последовательностях. Однако, LSTM и GRU в настоящий момент более исследованы для применения в управлении электрическим режимом ЭЭС.

Отдельной ветвью развития ИНС и рекуррентных сетей в частности являются **Байесовские нейронные сети**. В данных моделях значения весов сети носят не детерминированный, а вероятностный характер. Построить Байесовскую нейронную сеть, учитывающую вероятности параметров ИНС, можно применив метод Байесовского обратного распространения (Bayes By Backprop, BBV). Метод BBV [158, 159] позволяет получить апостериорное распределение весов нейронной сети [160]. Это распределение, как правило, является распределением Гаусса. Применение метода Bayes By Backprop для рекуррентных нейронных сетей описано в [161].

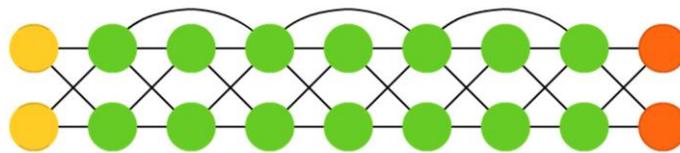


Рис. 1.21 – Глубокие остаточные сети.

Завершая обзор архитектур нейронных сетей, находящих применение в энергетике, опишем **глубокие остаточные сети** (Deep residual networks, DRN) (Рис. 1.21). DRN – это очень глубокие ИНС прямого распространения с дополнительными связями между слоями, которых обычно от двух до пяти, соединяющими не только соседние слои, но и более отдаленные. Было показано, что такие сети могут обучаться на моделях глубиной более 150 слоев, что намного больше, чем можно ожидать от обычных реализаций глубоких ИНС [163]. По своей структуре данный

тип ИНС близок к рекуррентным сетям, но не использует время в явном виде. Поэтому DRN часто сравнивают с LSTM без фильтров. Также, как и рекуррентные сети, DRN могут применяться для прогнозирования параметров ЭЭС. Например, в работе [162] прогнозируются значения нагрузки.

В качестве альтернативы применению ИНС для краткосрочного прогнозирования электрических режимов могут применяться модели динамического оценивания состояния, основанные на использовании фильтра Калмана или регрессионных моделях. В главе 2 будет проведен анализ возможности применения фильтра Калмана для данных задач. В ряде работ по прогнозированию нагрузки ЭЭС, таких как [173, 174], проводилось сравнение прогнозирования с использованием ИНС и традиционных алгоритмов прогнозирования на основе регрессии. При этом прогнозирование с использованием ИНС показало лучшие результаты.

Однако, большинство современных подходов по краткосрочному прогнозированию нагрузки с использованием ИНС рассматривают полносвязанные ИНС с достаточно малым количеством скрытых слоев [167 – 172]. Данный подход зачастую не позволяет реализовать универсальное решение, работающее для различных топологий электрической сети. Преобразование входных данных, например, вейвлет или Гильберта-Хуанга [175 – 181] позволяет лучше настроиться на прогнозирование определенного характера входных данных, что с другой стороны накладывает ограничение на универсальность модели прогнозирования.

Ограничение применения ИНС с полносвязанными слоями (перцептрон) для оценивания состояния и прогнозирования в том, что они могут быть обучены адекватно работать только в ограниченном объеме схемно-режимных ситуаций. К примеру:

- Изменение топологии сети, например, в результате коммутаций, приводит к необходимости повторного обучения ИНС.
- Пропадание части входных данных при перебоях в телеизмерениях также значительно меняет картину вектора состояний и соответственно влияет на результаты прогнозирования, получаемые с помощью нейронной сети.

Таким образом, задача заключается в том, чтобы получить надежно работающий алгоритм прогнозирования, устойчивый к значительным изменениям входных данных (как топологии, так и измерений).

В качестве базовой архитектуры ИНС для прогнозирования режимов будет рассмотрена рекуррентная нейронная сеть LSTM.

Классические рекуррентные нейронные сети (RNN) плохо справляются с ситуациями, когда необходимо выявить и запомнить долговременные тренды. Кроме того, они достаточно склонны к «переобучению». Так, в работе [170] показано, что для задачи предсказания данных (при обучении с учителем) ограниченные машины Больцмана, и в частности факторизованные условно ограниченные машины Больцмана (FCRBM) превосходят по точности рекуррентные нейронные сети. Однако, в данной работе рассматривались только классические RNN. Кроме того, в приведенных примерах не указана конкретная архитектура RNN и количество скрытых слоев. При этом, в большинстве случаев результаты сравнения точности на тестовой выборке были близкими. Только на некоторых сериях данных (причем, для среднего временного диапазона) ошибка по RNN была выше. Таким образом, можно сделать вывод, что применение RNN допустимо, но необходимо учитывать иерархичность по времени, т.е. проявление различных трендов в зависимости от рассматриваемого масштаба времени и их наложение друг на друга.

Использование рекуррентных LSTM сетей для прогнозирования нагрузки позволяет получить результаты, не уступающие сетям FCRBM [182]. При этом на основе сетей LSTM возможно построение глубоких сетей, что в свою очередь позволяет выявить более сложные зависимости в исходных данных. Что касается выбора конкретного типа ячеек рекуррентной сети, то в пользу выбора LSTM можно привести работу [183], в которой проанализированы различные варианты RNN (в частности LSTM и GRU) и выявлено, что LSTM с применением технологии dropout дает лучший результат на всех тестах.

1.5 Выводы по главе 1

Увеличение сложности и стохастичности поведения энергосистем требует адаптивных методов оперативного управления электрическими режимами таких энергосистем.

Исходя из проведенного анализа существующих методов оптимального управления и методов машинного обучения, применяемых для управления в ЭЭС, оптимизацию нормальных электрических режимов для оперативного и оптимального управления предлагается выполнять в два этапа:

- прогнозирование электрических режимов с использованием искусственных нейронных сетей;
- динамическая оптимизация режимов на основе прогноза.

На основании обзора архитектур искусственных нейронных сетей можно сделать вывод, что для прогнозирования электрических режимов лучшей из существующих архитектур является LSTM сеть.

В следующей главе будет обоснован выбор архитектуры ИНС для задач оценивания состояния и прогнозирования электрических режимов, а также предложена новая архитектура ИНС, позволяющая работать на данных крупной энергосистемы.

ГЛАВА 2. ОЦЕНИВАНИЕ СОСТОЯНИЯ И ПРОГНОЗИРОВАНИЕ С ИСПОЛЬЗОВАНИЕМ ГЛУБОКОГО ОБУЧЕНИЯ

В главе описываются модели, применяемые для статического и динамического оценивания состояния ЭЭС. На примере показываются проблемы в применении классических моделей динамического оценивания состояния. Анализируется динамика процесса изменения параметров электрического режима во времени с использованием эргодической теории и показываются ограничения в применении классических моделей динамического оценивания состояния. Далее исследуется применение искусственных нейронных сетей для прогнозирования параметров режима, выявляются проблемы существующих архитектур для прогнозирования параметров ЭЭС большого объема и предлагается новая архитектура ИНС, решающая данные проблемы.

2.1 Статическое оценивание состояния

Задача оценивания состояния заключается в получении такого установившегося режима, который был бы наиболее близок к имеющимся измерениям.

$$z - x(u) \rightarrow 0$$

где $z \in \mathbb{R}^m$ – измеренные параметры режима, m – количество измерений, $x(u)$ – вычисленные параметры режима по значениям вектора состояния системы $u \in \mathbb{R}^{2n-1}$, n – количество узлов модели электрической сети.

В классической постановке наиболее распространённым методом решения задачи оценивания состояния является метод взвешенных наименьших квадратов [239, 225], основанный на минимизации следующей целевой функции:

$$J = [z - x(u)]^T R_z^{-1} [z - x(u)] \quad (2.1)$$

Матрица R_z – ковариационная матрица, при отсутствии корреляционной зависимости между различными измерениями представляющая собой диагональную матрицу дисперсий измерений $R_z = \text{diag}\{\sigma_{z1}^2, \sigma_{z2}^2, \dots, \sigma_{zm}^2\}$.

Результатом оценивания состояния является установившийся режим, определяемый вектором состояния

$$u = [U_1, U_2, \dots, U_n, \delta_1, \delta_2, \dots, \delta_n]^T, \quad (2.2)$$

содержащим оцененные значения модулей напряжений и углов напряжений для каждого узла, n – общее количество узлов электрической сети.

Входными значениями алгоритма оценивания состояния для каждого рассматриваемого момента времени являются замеренные значения напряжений в узлах электрической сети, перетоки активной и реактивной мощности в ветвях и измерения инъекций активной и реактивной мощности в узлах (нагрузка и генерация).

Также при наличии векторных измерений в исходных данных могут присутствовать замеренные углы напряжений.

Решение задачи минимизации целевой функции оценивания состояния (2.1) проводится методами Ньютона-Рафсона, сопряженных градиентов, их сочетания [225], градиентным спуском, методом внутренней точки [226]. В условиях больших энергосистем с достаточно постоянными нагрузками статическое оценивание состояния дает хорошие результаты для ретроспективного анализа режимов, например, с целью уточнения потерь электроэнергии.

Проблемы статического оценивания состояния, такие, как фиктивная инъекция мощности в транзитных узлах и «размазывание» ошибок измерений по узлам электрической сети решаются алгоритмическими методами. Так, например, имея информацию об отсутствии генерации и нагрузки в узле можно в оцененном режиме зафиксировать нулевые значения мощности и провести дорасчет установившегося режима методом Ньютона-Рафсона. Проблема «размазывания» ошибок решается введением дополнительного алгоритма отбраковки грубых ошибок измерений [227].

2.2 Динамическое оценивание состояния

При выполнении статического оценивания состояния используется информация о взаимосвязях физических величин, определяющих режим работы электрической сети в конкретный момент времени, однако имеется еще информация об изменении этих величин во времени. С развитием измерительной и компьютерной техники точность и синхронность этой информации увеличивается. Использование информации об изменении параметров электрических режимов во времени возможно путем применения алгоритмов динамического оценивания состояния.

В рамках задачи оценивания состояния система принимается Марковской. Для прогнозирования слабоизменчивых компонент вектора состояния системы x (2.2) на короткий промежуток времени используется динамическое оценивание состояния на базе модификации фильтра Калмана.

Фильтр Калмана [243] является классическим методом динамического оценивания состояния. Суть фильтра Калмана заключается в следующем. Предположим, что имеется изменяющаяся во времени величина x . Закон ее изменения известен только с определенной погрешностью, так, что:

$$x_{i+1} = F_i x_i + \xi_i,$$

где F_i – матрица перехода на i -ом шаге, определяющая закон изменения x , ξ_i – неопределенная величина. Также на каждом шаге времени (начиная с первого) имеются фактические измерения исследуемой величины $z_{i+1} = x_{i+1} + \eta_{i+1}$, содержащие погрешность измерения. Идея фильтра Калмана состоит в том, что, чтобы получить наилучшее приближение к истинной величине x_{i+1} , необходимо выбирать «золотую середину» между неточным измерением z_{i+1} и $x_i + f(x_i)$ – предсказанием того, что ожидается получить. Показанию измерения назначается вес K_i , а предсказанному значению соответственно $1 - K_i$. Коэффициент Калмана меняется на каждой итерации и находится путем итерационной минимизации квадрата ошибки предсказания. Для этого вычисляется среднее значение квадрата ошибки:

$$E(e_{i+1}^2) = \frac{\sigma_\eta^2 (E(e_i^2) + \sigma_\xi^2)}{E(e_i^2) + \sigma_\xi^2 + \sigma_\eta^2}$$

и минимизирующее ошибку значение коэффициента Калмана на следующей итерации:

$$K_{i+1} = \frac{E(e_{i+1}^2)}{\sigma_\eta^2},$$

где σ_η^2 – дисперсия ошибки измерения, σ_ξ^2 – дисперсия ошибки модели.

Для нелинейной модели $f(x_i)$ применяется расширенный фильтр Калмана (Extended Kalman Filter) [125] или аппроксимирующие нелинейность более быстрые методы, например, сигма-точечный фильтр Калмана (Unscented Kalman Filter), основанный на одноименном ансцентном преобразовании [128, 129]. Применение сигма-точечного фильтра исключает необходимость явного вычисления Якобиана. Вместо этого используется ансцентное преобразование, подразумевающее выбор некоего минимального набора сэмплов (сигма-точек) для данных матожидания и ковариации искомого вектора с наложенными на него случайными помехами. По сигма-точкам строятся нелинейные функции прогноза, которые затем используются для вычисления матрицы кроссковариации, используемые в фильтре Калмана.

Для выбора этих точек применяются выражения вида:

$$x^{(i)} = \bar{x} + \left(\sqrt{N_x Z_x}\right)_i$$

$$W^{(i)} = W^{(i+N_x)} = \frac{1}{2N_x}$$

$$x^{(i+N_x)} = \bar{x} - (\sqrt{N_x Z_x})_i$$

где N_x – размерность искомого фазового вектора; i – индекс сигма-точки ($i \in [1..N_x]$); \bar{x} – среднее значение переменной; $W^{(i)}$ – вес i -ой сигма-точки; $\sqrt{N_x Z_x}$ – i -ый столбец матричного квадратного корня от матрицы ковариаций исходного нелинейного преобразования модели, умноженной на размерность фазового вектора. Ансцентные преобразования, характеризующие статистику распределения искомого вектора до моментов более высоких порядков, отличаются количеством сигма-точек и выбором весов.

2.3 Обоснование возможности прогнозирования параметров режима

Для оценки возможности прогнозирования параметров режима автором были проведены исследования применения классических методов динамического оценивания состояния на данных реальной энергосистемы (Иркутской энергосистемы). В рассматриваемой энергосистеме период формирования срезов для оценивания состояния и последующей оптимизации равен 30 минутам. Измерения поступают в SCADA систему значительно чаще и период оценивания состояния, с учетом вычислительных возможностей, может быть сокращен до 1 минуты. Однако, для целей автоматического оптимального управления, когда не рассматриваются задачи противоаварийного управления, 30 минутный период получения данных и соответственно расчета оценивания состояния может быть вполне достаточным.

Применение классических методов динамического оценивания состояния на 30 минутных срезах данных, получаемых от SCADA, оказалось не эффективным. Действительно, изменение нагрузки показывало хаотический характер. На рисунке (Рис. 2.1) показано изменение в течение двух суток измеренной активной мощности нагрузки и оцененной с помощью статического алгоритма оценивания состояния. По оси ординат отложен последовательный номер среза (получасовки). Изменения величин приведены для одного узла, но характер изменений подобен для большинства нагрузочных узлов сети.

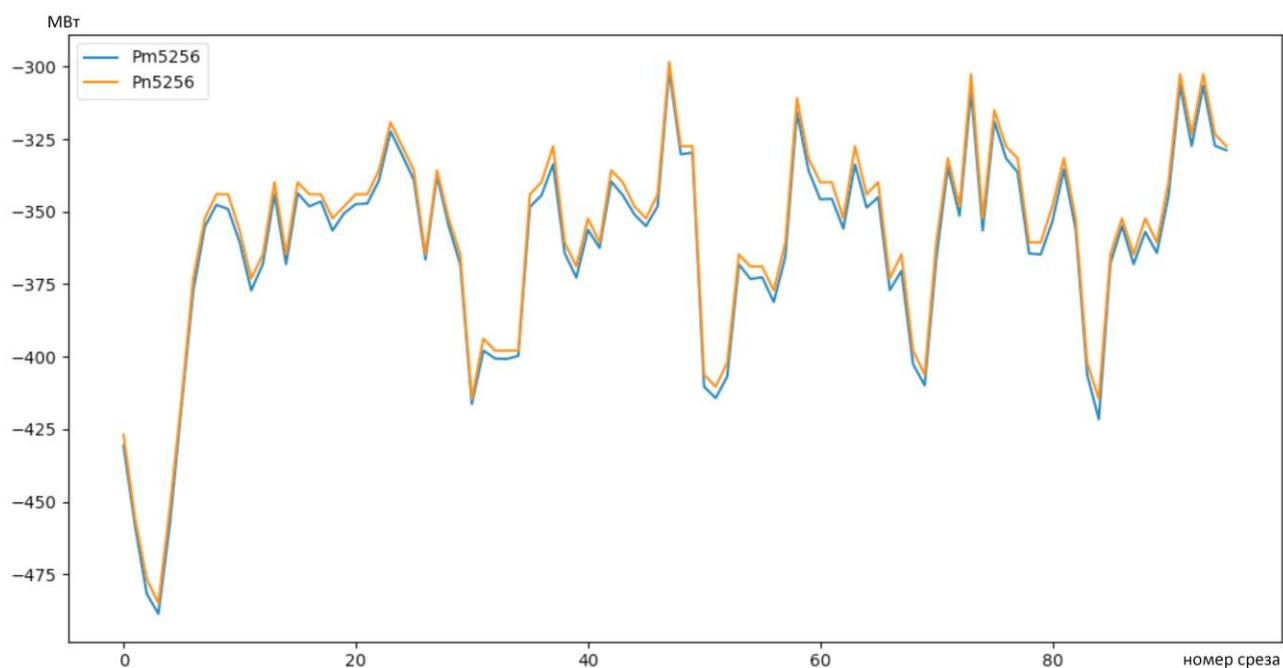


Рис. 2.1 – Измеренная и оцененная нагрузка в узле 5256. P_m – измеренная нагрузка, P_n – статически оцененная нагрузка.

Подобное хаотическое поведение наблюдается и в измерениях напряжений и потоков (Рис. 2.2, Рис. 2.3).

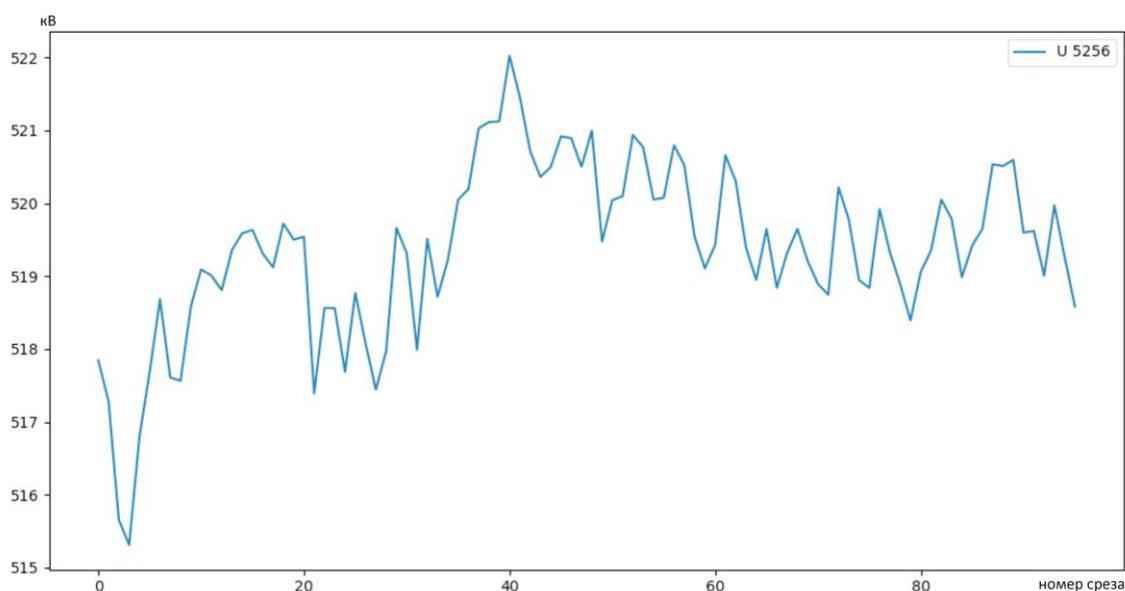


Рис. 2.2 – Измеренное напряжение в узле 5256.

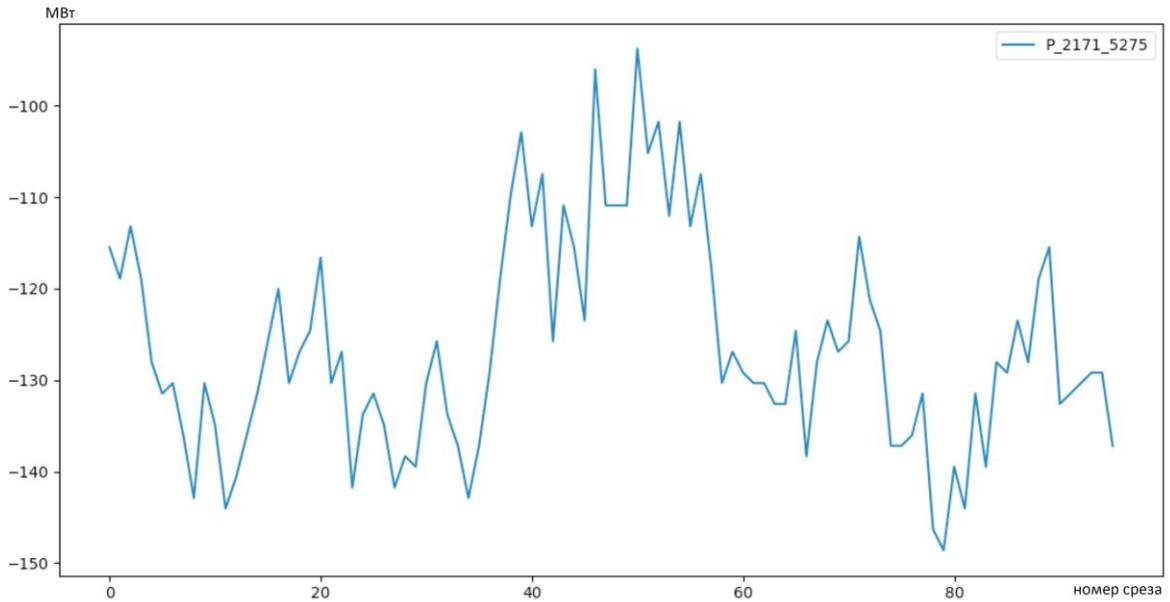


Рис. 2.3 – Измеренный переток по линии 2171-5275.

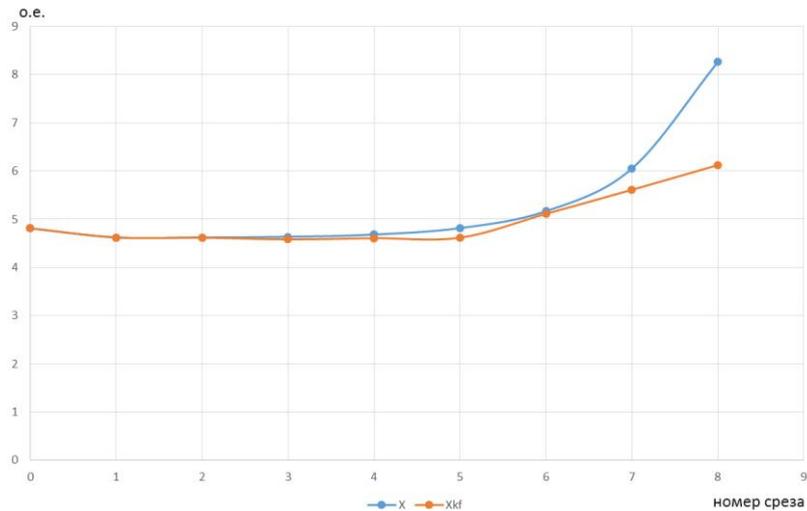


Рис. 2.4 – Отставание отфильтрованного сигма-точечным фильтром значения

В результате применения фильтра Калмана с линейной или усредняющей методом скользящего среднего моделью мы получаем режим с большей ошибкой, чем при статическом оценивании состояния. При этом наблюдается или запаздывание и закругление режима (Рис. 2.4), или в отдельных случаях наблюдается раскачивание и нарушение стабильности вычислительного алгоритма. Такое поведение объясняется тем, что погрешность модели ξ_i значительно превышает погрешность измерений η_{i+1} .

2.4 Анализ динамики хаотического процесса

Для того, чтобы понять возможность построения адекватной модели предсказания процесса изменения режимов во времени, обратимся к эргодической теории [228, 229]. Процесс изменения режимов при этом будем рассматривать как динамическую систему с неизвестным законом управления.

Для исследования поведения системы в окрестности произвольной траектории используются показатели Ляпунова, которые характеризуют степень растяжения и сжатия в фазовом пространстве движения системы (изменения ее параметров) вдоль устойчивых и неустойчивых направлений (Рис. 2.5).

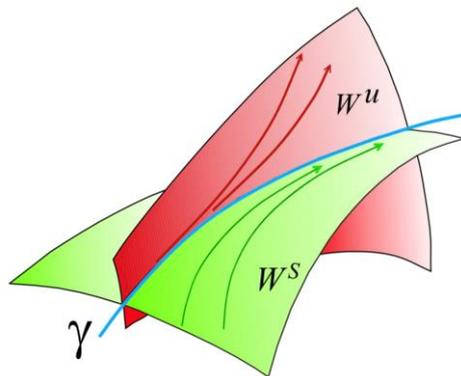


Рис. 2.5 – Траектория движения системы – γ . W^S – устойчивое многообразие, W^U – неустойчивое многообразие траекторий системы (рисунок взят из [229]).

Пусть динамика системы задается системой дифференциальных уравнений:

$$\dot{x} = f(x(t), c), \quad (2.3)$$

где x – вектор динамических переменных системы зависящих от времени t , c – совокупность не изменяющихся параметров. Рассмотрим типичную фазовую траекторию $x(t)$ системы (2.3) и близкую к ней траекторию

$$x_1(t) = x(t) + \xi(t).$$

Функция, определяющая показатели Ляпунова, запишется как:

$$\Lambda(\xi) = \lim_{t \rightarrow \infty} \frac{1}{t} \ln \frac{|\xi(t)|}{|\xi(0)|} \quad (2.4)$$

При $\xi(0) \rightarrow 0$ значения функции (2.4) представляют собой вектор с размерностью, равной размерности фазового пространства n :

$$\Lambda(\xi) = \{\lambda_1, \lambda_2, \dots, \lambda_n\}. \quad (2.5)$$

Если $\Lambda(\xi)$ не содержит положительных показателей, то хаотическая составляющая отсутствует и эволюция системы полностью предсказуема.

Получение закона изменения параметров режима во времени в виде (2.3) невозможно в виду сложности рассматриваемой системы. Поэтому был применен метод реконструкции динамической системы по имеющимся измерениям с использованием теоремы Такенса. Данная теорема обосновывает возможность восстановления странного аттрактора хаотической динамической системы из последовательности измерений одного из ее параметров, взятых через равные промежутки времени τ :

$$Z = \{z(t_0), z(t_0 + \tau), \dots, z(t_0 + (m - 1) \cdot \tau)\}. \quad (2.6)$$

Данный подход к анализу временных рядов был математически обоснован в работе Ф.Такенса [230, 231]. Восстановление всего d -мерного фазового пространства (вложенного пространства) по измерениям одной переменной возможно за счет того, что все переменные вектора состояния системы связаны в общем нелинейном процессе.

Максимальный показатель Ляпунова определяется, как:

$$\lambda_{max} = \lim_{t \rightarrow \infty} \lim_{\varepsilon \rightarrow 0} \frac{1}{t} \ln \left(\frac{|z(t) - z_\varepsilon(t)|}{\varepsilon} \right). \quad (2.7)$$

Для определения максимального показателя Ляпунова на основе конечного ряда измерений (2.6) воспользуемся алгоритмом, предложенным Розентейном [232]. Рассмотрим представление данных временного ряда как траекторию в реконструированном вложенном пространстве. Отдельные траектории движения системы в реконструированном пространстве колеблются вдоль основного тренда, определяемого спектром показателей Ляпунова. Тогда, можно рассматривать расстояние $\Delta_0 = |z(t_0) - z_\varepsilon(t_0)|$ как отклонение, которое должно расти экспоненциально со временем таким образом, что $\Delta_t \approx \Delta_0 \varepsilon^{\lambda t}$. В этом случае λ будет равна максимальному показателю Ляпунова. Спектр показателей Ляпунова вычисляется как:

$$\lambda_\tau(t) = \lim_{\varepsilon \rightarrow 0} \frac{1}{\tau} \ln \left(\frac{|z(t + \tau) - z_\varepsilon(t + \tau)|}{\varepsilon} \right). \quad (2.8)$$

Если спектр $\lambda_\tau(t)$ демонстрирует линейное увеличение с одинаковым наклоном для большинства из траекторий, то этот наклон может быть взят как оценка максимального показателя Ляпунова λ_{max} (Рис. 2.6).

В качестве измерений, по которым определяется максимальный показатель Ляпунова, необходимо взять переменную из вектора состояния системы, испытывающую наибольшее влияние от других переменных системы. Для рассматриваемой системы это будет значение напряжения на шинах высокого напряжения, удаленных от шин, на которых производится поддержание напряжения регуляторами.

Для определения показателей Ляпунова была использована библиотека нелинейного анализа временных рядов TISEAN [233].

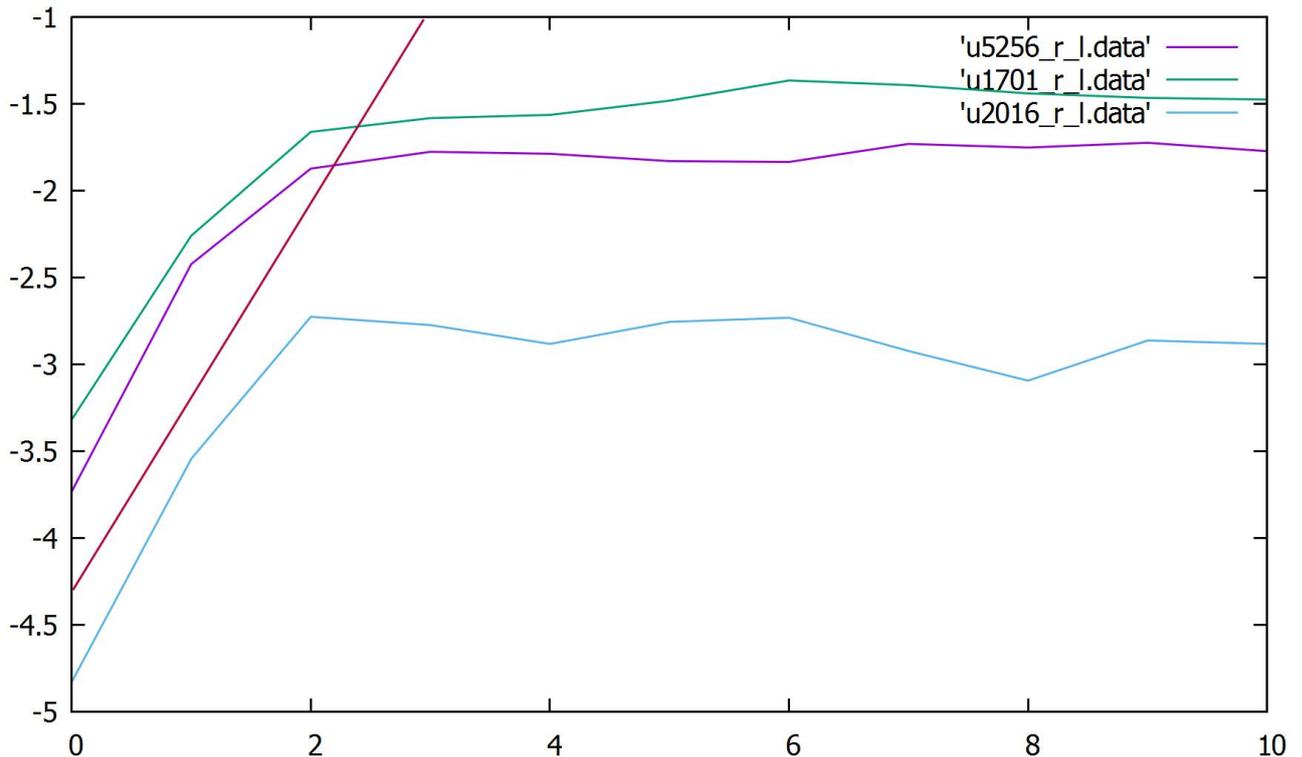


Рис. 2.6 – Определение максимального показателя Ляпунова

Максимальный показатель Ляпунова для рассматриваемой энергосистемы, определенный по вектору состояния энергосистемы, равен $\lambda_{max} = 2,238$. Таким образом, подтверждается хаотическое поведение динамической системы.

Имея хаотическое поведение системы, важно понимать, возможно ли выполнить предсказание поведения хаотической системы и какой набор данных необходим для выполнения адекватного предсказания. Скорость генерации новой информации в ряде измерений можно связать со скоростью роста расстояний в пространстве измерений по работе Песина [234]. Оценить скорость генерации информации можно по значению средней взаимной информации:

$$I_{AB} = \sum_{a_i, b_i} P_{AB}(a_i, b_i) \log_2 \left(\frac{P_{AB}(a_i, b_i)}{P_A(a_i)P_B(b_i)} \right),$$

где a_i – событие из множества A , b_i – событие из множества B , $P_A(a_i)$ – вероятность события из множества A , $P_B(b_i)$ – вероятность события из множества B , $P_{AB}(a_i, b_i)$ – взаимная вероятность событий.

Если принять в качестве множества событий A , измерения $z(t)$, наблюдаемые в моменты времени t , а в качестве событий множества B – измерения $z(t + \tau)$, то по функции средней взаимной информации можно определить оптимальные для предсказаний параметры ряда измерений. Так, для выбора оптимальной дискретизации измерений в работе [228] находится первый минимум функции:

$$C(\tau) = \sum_t |z(t) - \bar{z}| |z(t + \tau) - \bar{z}|,$$

$$\bar{z} = \frac{1}{n} \sum_{t=1}^n z(t)$$

При заранее заданной дискретности измерений (как это есть в исследуемой системе) можно варьировать размер вектора измерений n , используемый для прогнозирования:

$$\min_n C(n) = \begin{cases} \sum_t |z(t) - \bar{z}| |z(t + \tau) - \bar{z}| \\ \bar{z} = \frac{1}{n} \sum_{t=1}^n z(t) \end{cases}$$

Из приведенных расчетов (Рис. 2.7) видно, что первый явный минимум проявляется после 33-го среза измерений, что при периодичности измерений в 30 минут приближается к глубине среза в одни сутки. Всего при анализе системы использовался архив измерений глубиной от одного месяца. Таким образом, для получения адекватного прогноза следующего режима в модельной функции необходимо использовать более сложные модели, чем линейные или скользящего среднего, которые часто применяются в фильтре Калмана.

Как справедливо отмечается в [235], применение динамического оценивания состояния с использованием фильтра Калмана ограничено медленным изменением

параметров режима и горизонтом прогнозирования до 1 мин. Таким образом, область применения динамического оценивания состояния, предлагаемого в [235] и подобных работах, ограничена автоматическим управлением энергоустановками, в том числе с целью противоаварийного управления.

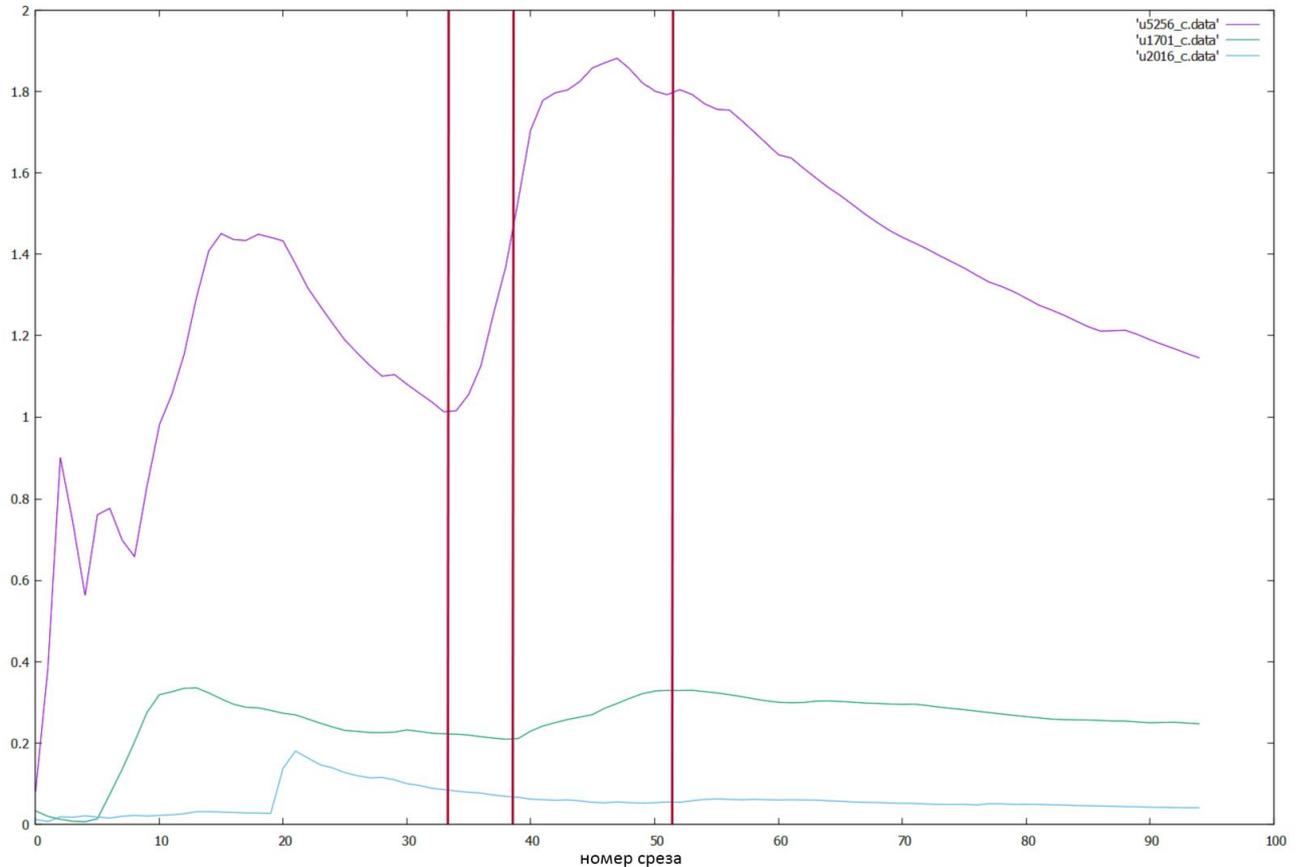


Рис. 2.7 – Определение минимальной глубины среза

Для целей оптимального управления требуется модель, обеспечивающая прогноз на время порядка суток и входной архив данных не менее месяца. Такой моделью, как предлагается в [121], могут быть модели основанные на искусственных нейронных сетях. Причем возможны два варианта использования таких моделей:

- непосредственное использование для получения прогноза;
- использование как модели поведения системы в динамическом оценивании состояния с использованием фильтра Калмана.

Второй вариант применения ИНС предполагает применение нелинейного фильтра Калмана, в частности сигма-точечного фильтра.

2.5 Прогнозирование режимов с использованием ИНС

2.5.1 Прогнозирование с использованием рекуррентных сетей LSTM

Как было показано в главе 1, из существующих архитектур искусственных нейронных сетей оптимальным для прогнозирования параметров режима являются сети, построенные на архитектуре LSTM, которые решают проблему исчезающих градиентов, мешающую классическим рекуррентным сетям обучать долгосрочные зависимости.

Входной информации для LSTM слоя ИНС, является последовательный набор входных измерений $z_t \in \mathbb{R}^m$, где m – количество измерений.

Структурная схема ячейки LSTM показана на Рис. 2.8. В LSTM есть три основных вида элементов, называемых «гейтами»: входной (i_t), забывающий (f_t) и выходной (o_t), внутреннее состояние ячейки c_t . Также используется внутреннее промежуточное преобразование в ячейке LSTM – \tilde{c}_t .

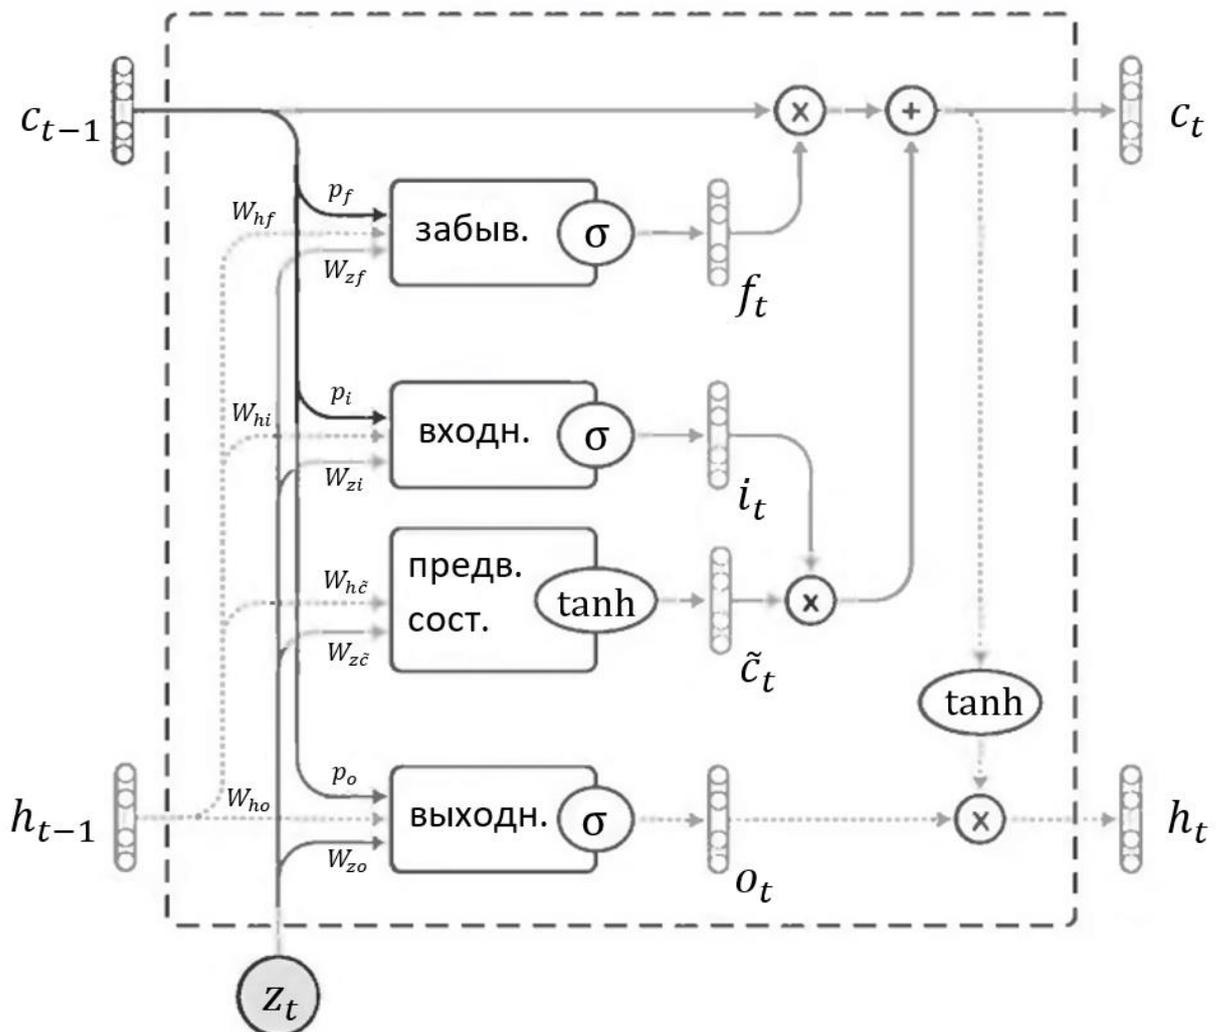


Рис. 2.8 – Ячейка LSTM

Преобразования входных величин при прямом ходе через слой LSTM записывается следующим образом:

$$\begin{aligned}\tilde{c}_t &= \tanh(W_{zc}z_t + W_{hc}h_{t-1} + b_{\tilde{c}}) \\ i_t &= \sigma(W_{zi}z_t + W_{hi}h_{t-1} + p_i \odot c_{t-1} + b_i) \\ f_t &= \sigma(W_{zf}z_t + W_{hf}h_{t-1} + p_f \odot c_{t-1} + b_f) \\ o_t &= \sigma(W_{zo}z_t + W_{ho}h_{t-1} + p_o \odot c_{t-1} + b_o) \\ c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t\end{aligned}$$

где h_t – вектор скрытого состояния во время t . W – матрицы весов для соответствующего преобразования, определяющегося индексами. Так, индекс zi обозначает веса входных значений z_t в значения входного гейта i_t . b – векторы свободных членов используемых в соответствующем преобразовании, определяемым индексом. p – веса дополнительных связей (peerholes), позволяющих явным образом учитывать состояние ячейки LSTM с предыдущего шага.

Обратное распространение градиентов на каждой итерации процесса обучения определяются следующими выражениями:

$$\begin{aligned}\delta h_t &= \Delta_t + W_{h\tilde{c}}^T \delta \tilde{c}_{t+1} + W_{hi}^T \delta i_{t+1} + W_{hf}^T \delta f_{t+1} + W_{ho}^T \delta o_{t+1} \\ \delta o_t &= \delta h_t \odot \tanh(c_t) \odot \sigma(o_t) \\ \delta c_t &= \delta h_t \odot o_t \odot \text{sech}^2(c_t) + p_o \odot \delta o_t + p_i \odot \delta i_{t+1} + p_f \odot \delta f_{t+1} + \delta c_{t+1} \odot f_{t+1} \\ \delta f_t &= \delta c_t \odot c_{t-1} \odot \sigma'(f_t) \\ \delta i_t &= \delta c_t \odot \tilde{c}_t \odot \sigma'(i_t) \\ \delta \tilde{c}_t &= \delta c_t \odot i_t \odot \text{sech}^2(\tilde{c}_t)\end{aligned}$$

Здесь Δ_t – вектор частных производных, получаемый из вышележащего слоя ИНС или из обучающей модели, если данный слой LSTM последний.

В качестве алгоритма оптимизации, применяемого при обратном распространении ошибки в процессе обучения ИНС, выбран алгоритм стохастической оптимизации Adam [237], название которого расшифровывается, как адаптивная оценка моментов. Сравнение из [237] на многоуровневом персептроне приведено на Рис. 2.9 – Сравнение скорости обучения различных оптимизационных алгоритмов на ИНС прямого распространения (2 уровня по 1000 ячеек ReLU).

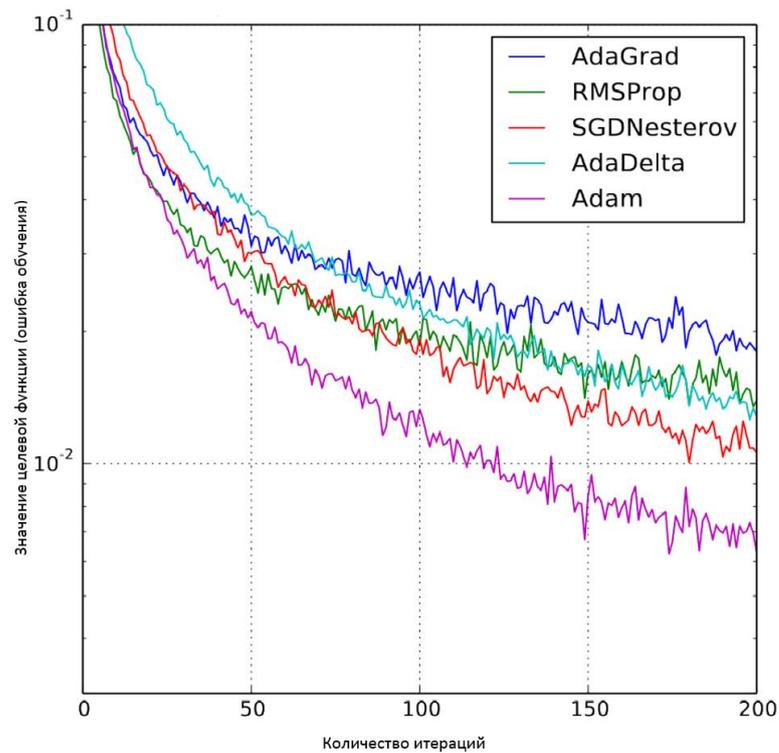


Рис. 2.9 – Сравнение скорости обучения различных оптимизационных алгоритмов на ИНС прямого распространения (2 уровня по 1000 ячеек ReLU).

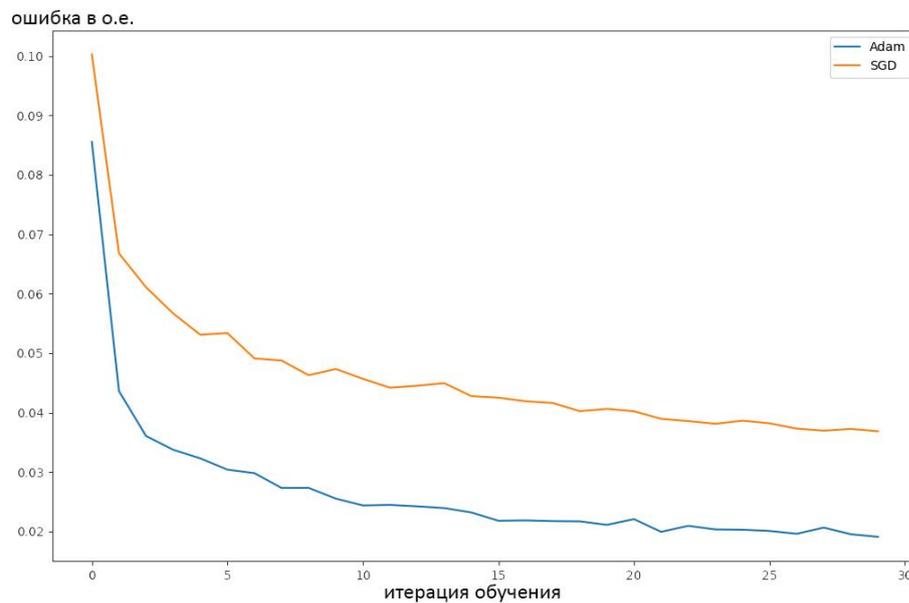


Рис. 2.10 – Сравнение скорости обучения сети LSTM.

Для сети LSTM наилучшие результаты показывают алгоритмы оптимизации SGD и Adam. Однако, алгоритм Adam превосходит по эффективности SGD (Рис. 2.10). Сравнение проводилось на сети с одним входным, одним выходным и одним слоем LSTM.

2.5.2 Применение Байесовских нейронных сетей

Одной из важных особенностей исходных данных для оценивания состояния является их вероятностный характер. Входные измерения, как правило, задаются не просто значением математического ожидания, но также сопровождаются дисперсиями. Распределение вероятности при этом предполагается нормальным. Это дает дополнительную информацию для обучения нейронной сети. Кроме того, если на выходе нейронной сети мы будем иметь не только математическое ожидание параметров режима, но и дисперсию этих параметров, то такая информация позволит принимать более обоснованные решения по управлению режимами на основе результатов оценивания состояния. Таким образом, обоснованным будет применение Байесовских ИНС.

Построить Байесовскую нейронную сеть, учитывающую вероятности параметров ИНС, можно, применив метод Байесовского обратного распространения (Bayes By Backprop или сокращенно BBB). Метод Bayes by Backprop (BBB) [158, 159] позволяет получить апостериорное распределение весов нейронной сети $\theta \in \mathbb{R}^d$, где d – размерность пространства параметров нейронной сети [160]. Это распределение, как правило, является распределением Гаусса.

Пусть $\log p(x|\theta, z)$ – логарифм правдоподобия модели, тогда обучение модели можно выполнять, минимизируя свободную вариационную энергию:

$$\mathcal{L}(\theta) = \mathbb{E}_{q(\theta)} \left[\log \frac{q(\theta)}{p(x|\theta, z)p(\theta)} \right], \quad (2.9)$$

где $p(\theta)$ – априорно заданная дисперсия параметров.

Минимизация (2.9) эквивалентна максимизации логарифма правдоподобия $p(x|\theta, z)$ с учетом расстояния Кульбака-Лейблера между вычисленной плотностью вероятности параметров ИНС и действительной апостериорной вероятностью [160]:

$$\mathcal{L}(\theta) = -\mathbb{E}_{q(\theta)} [\log p(x|\theta, z)] + \text{KL}[q(\theta)||p(\theta)].$$

Данную минимизацию можно рассматривать как затухание отклонения параметров к математическому ожиданию, регулируемое стандартным отклонением параметров ИНС.

Применение метода Bayes By Backprop для рекуррентных нейронных сетей описано в [161].

Архитектура нейронной сети для оценивания состояния с применением глубокого обучения представлена на Рис. 2.11. На вход ИНС подается архив измерений и состояний коммутационных аппаратов (КА), а также текущая дата и время.

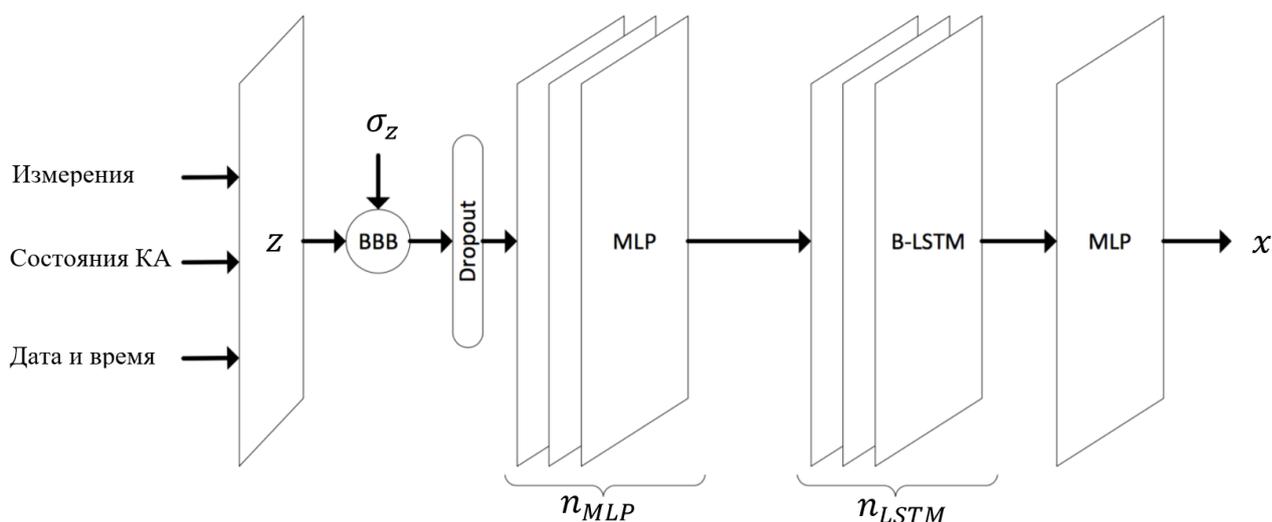


Рис. 2.11 – Архитектура нейронной сети для прогнозирования параметров режима.

Особенности применяемой архитектуры:

1) Входной полносвязанный слой. Для того, чтобы сформировать устойчивую взаимосвязь между параметрами одного режима, возможно применение несколько входных слоев.

Весы Байесовской нейронной сети инициализируются с использованием случайного значения r . Если для скрытых слоев случайное значение задается нормальным распределением $r \sim \mathcal{N}(0, 1)$, то для входного слоя нормальное распределение определяется дисперсией измерений, являющихся входными данными для нейронной сети $r \sim \mathcal{N}(0, \sigma_z^2)$.

2) В модели применяется несколько скрытых LSTM слоев, что позволяет выявить более сложные взаимосвязи параметров в разрезе времени. При этом на вход ИНС подается также информация о текущем моменте времени. Подобный подход применялся в [159] только для сетей прямого распространения типа MLP.

3) Полносвязанный выходной слой, обеспечивает масштабирование выходного вектора, не зависящее от времени.

Проблему учета коммутаций, частично решает Dropout на входном слое. Однако, как правило, задача прогнозирования режимов решается независимо для каждого топологического состояния сети, а состояние сети формируется по коммутациям из планируемого графика ремонтов.

2.5.3 Пример использования разработанного алгоритма прогнозирования

Исследования представленной архитектуры проводились на модели энергосистемы Иркутской области (Рис. 2.13). В большем масштабе изображение схемы приведено в приложении 1. Рассматриваемая модель энергосистемы включает электрические сети Иркутской области напряжением 500 кВ - 110 кВ. Генераторы в модели в основном заданы узлами того напряжения, на котором фактически работают соответствующие генераторы (6 кВ – 15 кВ). Некоторая генерация представлена в виде эквивалентных генераторов на шинах высокого или среднего напряжения. Нагрузка в основном задана на низкой стороне трансформаторов (Рис. 2.12а) или на отпайке линий электропередачи (Рис. 2.12б). Генераторных узлов в модели – 486, нагрузочных – 485. Общее количество узлов в модели узлы/ветви для этой системы – 1248, ветвей – 1481.

Расчеты проводились на рабочей станции со следующими параметрами:

- Платформа на базе процессора Intel Xeon W-2125 4 ГГц с ОЦУ 32 Гб.
- Две связанные GPU: GeForce RTX 2070 SUPER.
- Tensorflow-gpu 1.15.0 и CUDA 7.5.

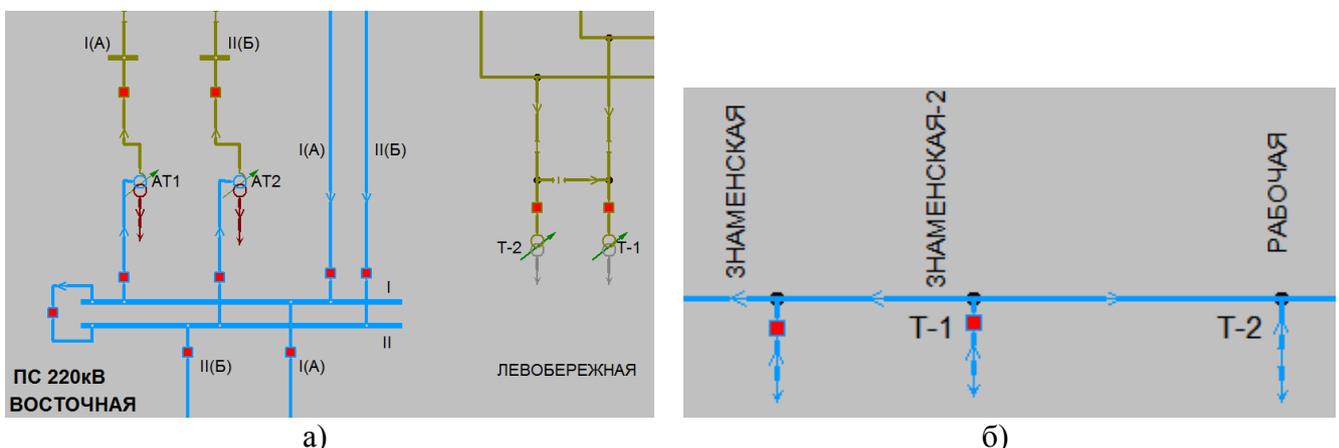


Рис. 2.12 – Задание нагрузки в модели.

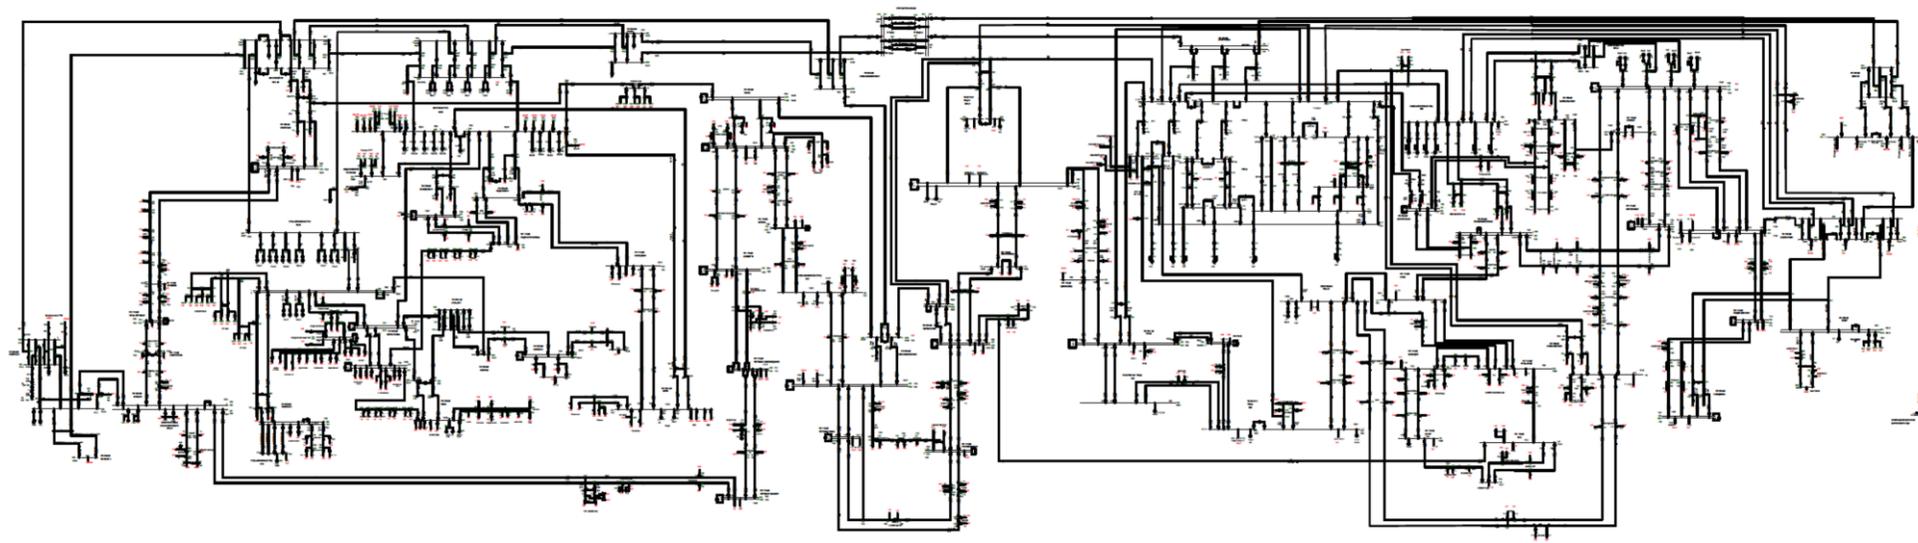


Рис. 2.13 – Тестовая схема.

Исходными данными на которых обучалась ИНС являлся архив получаемый из SCADA, глубиной от одного месяца до одного года. Проведенные эксперименты по обучению и тестированию ИНС показали, что архива глубиной в месяц достаточно для отладки и тестирования архитектуры ИНС. Поэтому для ускорения работы большинство экспериментов проводилось на архиве глубиной в месяц. Для обучения использовались все измеряемые параметры режима, включая напряжения, активную и реактивную мощности генерации, активную и реактивную мощности нагрузки, перетоки мощности по линиям электропередачи, а также получаемые в SCADA состояния коммутационных аппаратов. Если в составе исходных данных имеется информация о метеоусловиях, то качество прогнозирования будет лучше, но в данном исследовании эта информация отсутствовала.

Параметрами, которые прогнозировала ИНС, являлись активные и реактивные мощности генерации и нагрузки, а также напряжения в балансирующих по реактивной мощности узлах для последующего расчета установившегося режима.

Тестируемая архитектура ИНС соответствовала представленной на Рис. 2.13. Настраиваемые параметры ИНС следующие:

- Количество входных полносвязанных слоев – **1**.
- Количество слоев LSTM – **2**. Количество слоев LSTM больше 3-х при значительном замедлении обучения не давало существенного эффекта.
- Количество выходных полносвязанных слоев – **1**.
- Количество ячеек входного слоя на один вход – **1** (размер слоя соответствует размеру входного вектора).
- Количество ячеек сети LSTM на один вход – **32**.
- Количество ячеек выходного слоя на один выход – **1** (размер слоя соответствует размеру выходного вектора).
- Размер обучающей выборки – **0.6** от глубины всего рассматриваемого архива данных.
- Размер валидационной выборки – **0.3** от глубины всего рассматриваемого архива данных.

- Размер тестовой выборки – **0.1** от глубины всего рассматриваемого архива данных.
- Глубина минибатча для слоя LSTM – **8** временных срезов.
- Коэффициент отсева (dropout ratio) – **0.3**. Проводились эксперименты с различными коэффициентами. Наибольшая устойчивость при тестировании на различных тестовых выборках получалась при значении коэффициента dropout равного 0.3.
- Количество эпох обучения – от **30**. Количество эпох увеличивалось пока наблюдалось уменьшение ошибки обучения.

В результате экспериментов с обучением ИНС были получены следующие результаты. Если нейронная сеть обучена прогнозировать небольшое количество параметров, тогда обучение эффективно (Рис. 2.14), и результаты прогноза с использованием обученной нейронной сети близки к реальному (Рис. 2.15). На представленных рисунках количество прогнозируемых параметров равно 6.

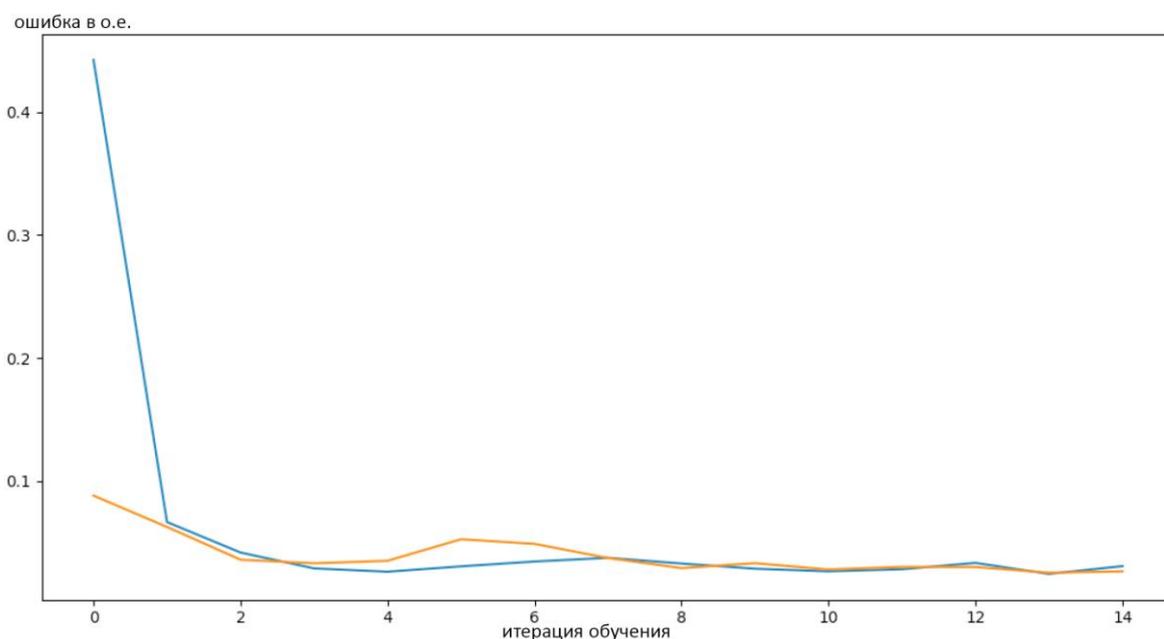


Рис. 2.14 – Ошибка обучения и ошибка на тестовой выборке при малом количестве прогнозируемых параметров.

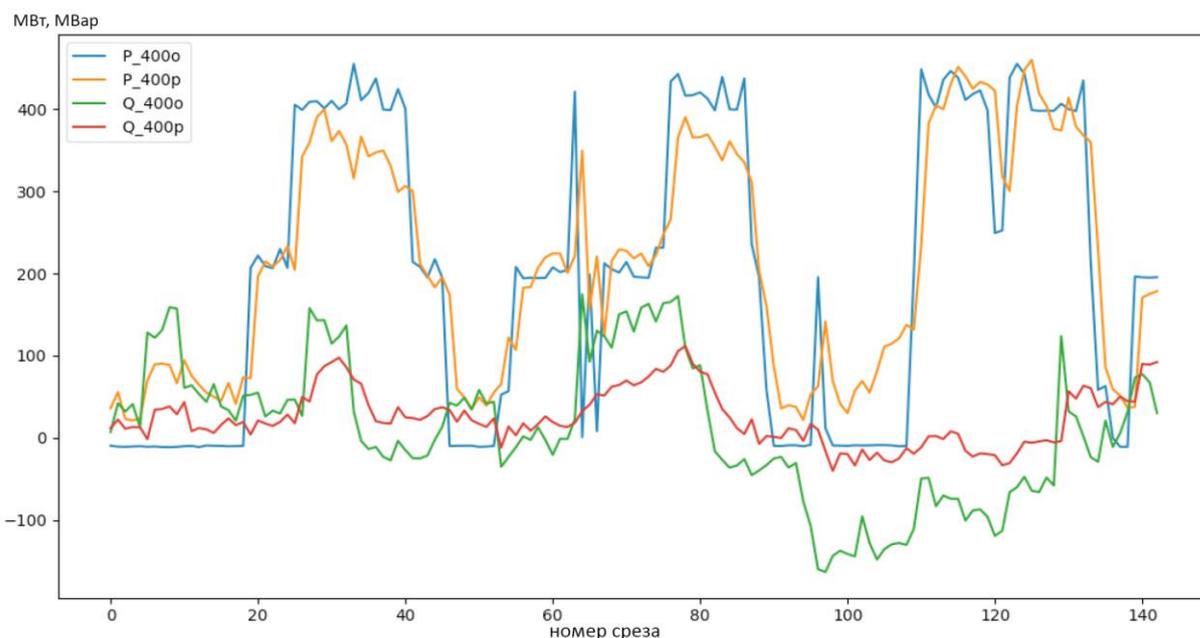


Рис. 2.15 – Результат прогноза при малом количестве прогнозируемых параметров (индекс “о” – обозначает измерение, индекс “р” – прогноз).

В случае, когда данная архитектура ИНС применялась для прогнозирования большого количества величин (100), то результаты стали неудовлетворительными (Рис. 2.16). При этом, в качестве входных величин использовался не весь набор измеряемых данных, а только часть.

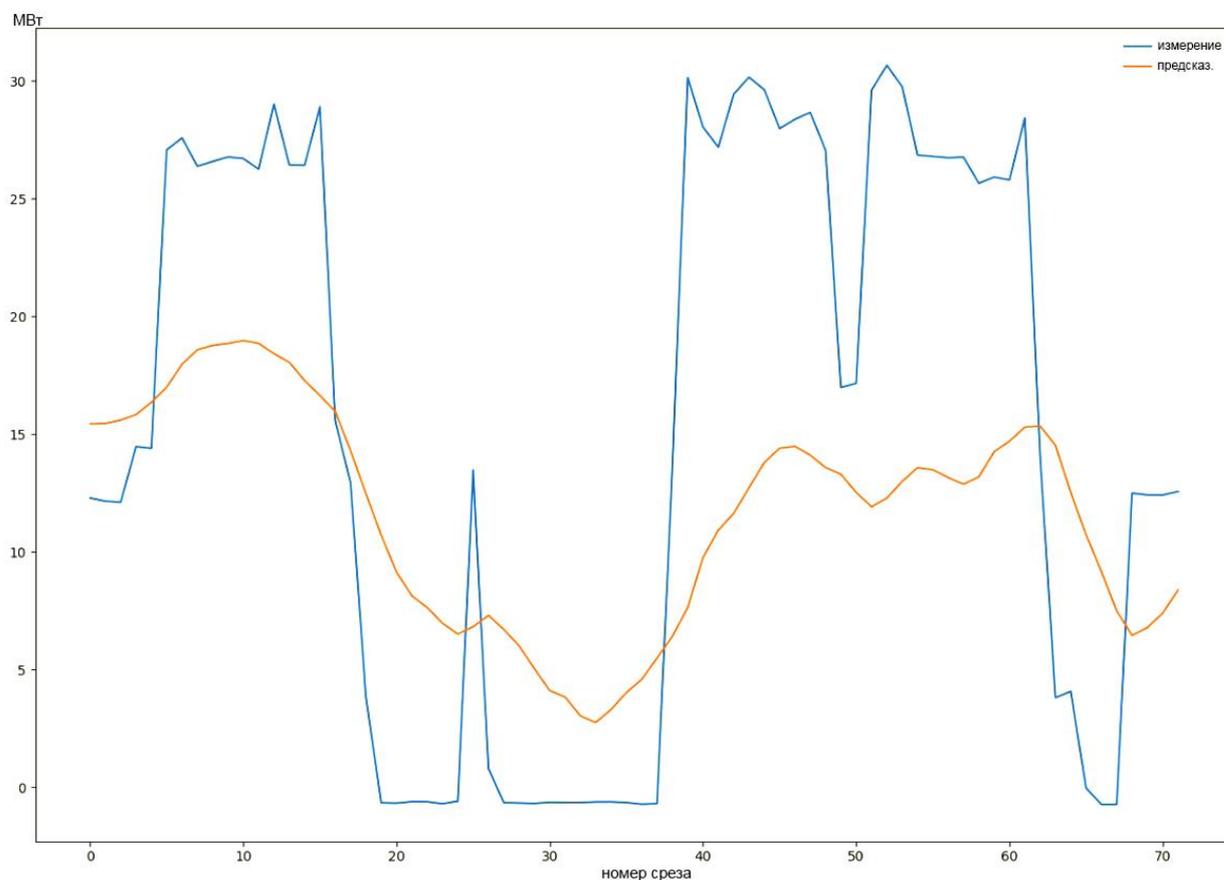


Рис. 2.16 – Результаты прогнозирования на реальной сети.

Было проведено исследование качества прогнозирования с использованием глубокой LSTM сети для различного количества прогнозируемых параметров режима и разного размера слоя LSTM. На рисунках (Рис. 2.17, Рис. 2.18) показаны среднеквадратичные и абсолютные отклонения прогноза от реальных значениях полученные на тестовой выборке. Размер LSTM слоев задан в относительных единицах по отношению к размеру входного вектора измерений. В результате расчетов видно, что классическая архитектура ИНС на основе LSTM сети позволяет прогнозировать лишь небольшое количество параметров. После 10 выходных параметров качество уже не улучшается при увеличении размера ИНС и увеличении количества итераций обучения. Причем, стоит отметить, что среднеквадратичное отклонение не в полной мере отражает качество обучения, так как сдвиг по времени прогноза, который достаточно хорошо отражает картину изменения параметров режима, достаточно сильно увеличивает среднеквадратичное отклонение.

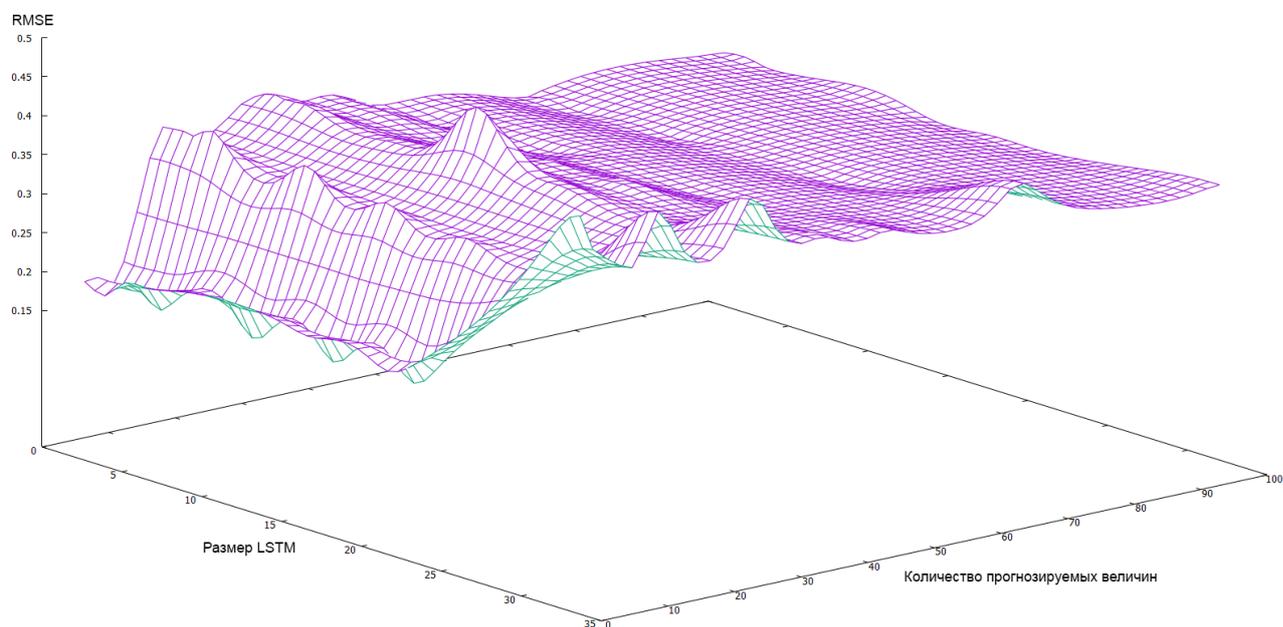


Рис. 2.17 – Среднеквадратичное отклонение прогноза от реальных измерений на тестовой выборке.

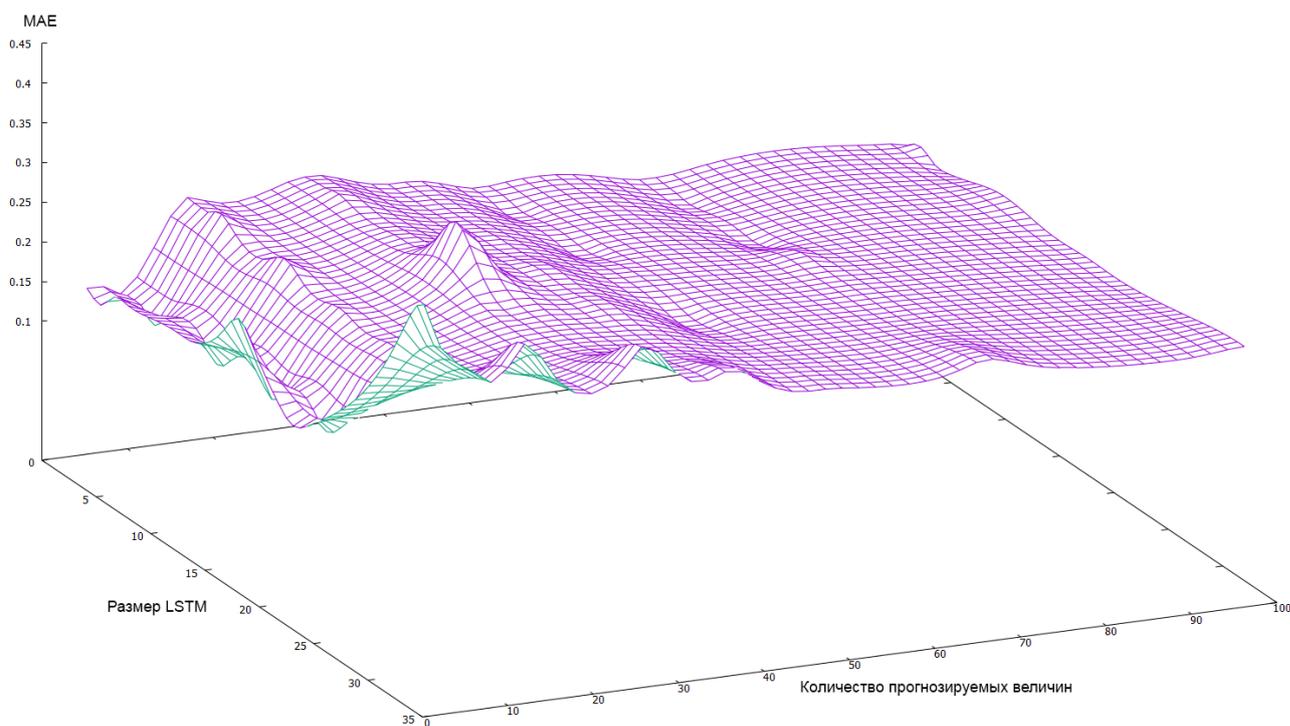


Рис. 2.18 – Среднее абсолютное отклонение прогноза от реальных измерений на тестовой выборке.

Для прогнозирования всех параметров режима на основе полного набора измерений на имеющейся рабочей станции не хватило ресурсов. Количество обучаемых параметров ИНС: 1 238 055 300. Количество входных параметров при этом было равно 4700. Количество прогнозируемых – 100.

2.6 Искусственная нейро-аналитическая сеть

2.6.1 Описание архитектуры нейро-аналитических сетей

Для решения проблемы сложности обучения сети LSTM на электрической сети большого размера была разработана архитектура искусственной нейро-аналитической сети (НАС). Далее слово «искусственная» в названии опущено, так как в работе речь идет только об искусственных нейронных сетях. Предложенный подход предполагает разделение всей исследуемой электрической сети на подсистемы, в каждой из которых прогнозируется лишь небольшое количество параметров.

Для каждой из подсистем с небольшим количеством выходных параметров используется надежно работающая на таком объеме архитектура, показанная на

Рис. 2.19. Результаты прогноза – это исходные данные для расчета установившегося режима (УР): инъекции активной и реактивной мощности и напряжения в узлах, балансирующих по напряжению.

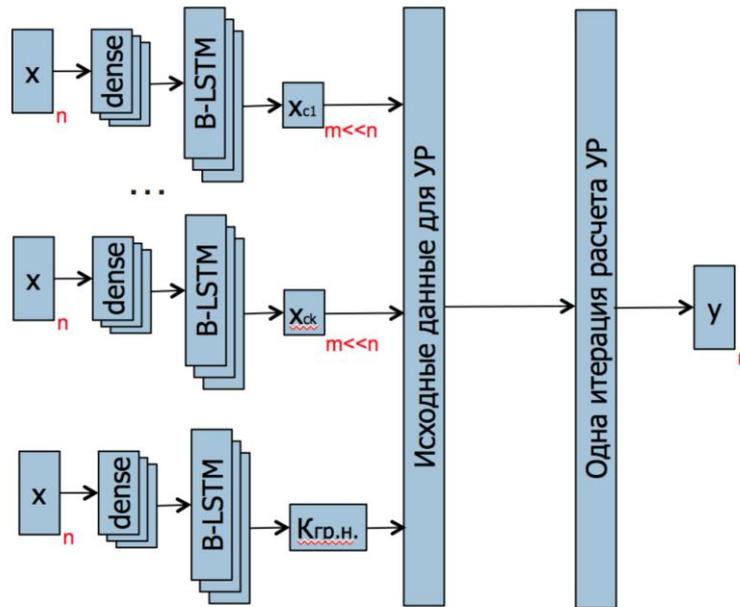


Рис. 2.19 – Нейро-аналитическая сеть.

Выходные параметры каждого кластера объединяются в общий вектор исходных данных для расчета УР и производится один шаг алгоритма расчета установившегося режима методом Ньютона-Рафсона. Этот расчет выполняется на каждом этапе итеративного процесса обучения и прогнозирования. Таким образом, аналитический метод расчета потока мощности встроен в единую модель (Рис. 2.19), участвующую в процессе обратного распространения градиентов, получаемых по величине ошибки прогнозирования.

Разделение электрической сети на подсети выполняется с использованием иерархической кластеризации методом главных компонент [238]. Мерой расстояния в алгоритме кластеризации выступает электрическое сопротивление между узлами сети. Критерием окончания разбиения на кластеры является допустимый максимальный размер кластера.

Компоненты вектора градиента аналитической части НАС рассчитываются на основе неявного дифференцирования отклонения выходного вектора прогнозируемых переменных u относительно измеренных:

$$\varepsilon = (y(u) - \bar{y})$$

Для этого решается система линейных уравнений:

$$J \left[\frac{d\varepsilon}{dx_{ck}} \right] = \left[\frac{d\varepsilon}{du} \right],$$

где $J = \left[\frac{dx_{ck}}{du} \right]$ – транспонированная матрица Якоби; x_c – вектор независимых параметров; $u = [u_{r1}, u_{i1}, \dots, u_{rn}, u_{in}]$ – вектор действительных и мнимых составляющих узловых напряжений, полученный в результате расчета одной итерации УР. В случае, если установившийся режим не сходится на данной итерации обучения, то искусственно задается высокое значение

2.6.2 Результаты обучения и прогнозирования с помощью нейро-аналитической сети

Нейро-аналитическая сеть (НАС) проверялась на той же модели электрической сети (Рис. 2.13). В результате кластеризации была автоматически сформирована НАС со следующими характеристиками. Количество входных параметров (измерений) – 4731. Количество кластеров – 100. Общее количество независимых параметров необходимых для расчета УР – 220. Количество слоев ИНС по всем кластерам – 694. Количество обучаемых параметров – 567 200.

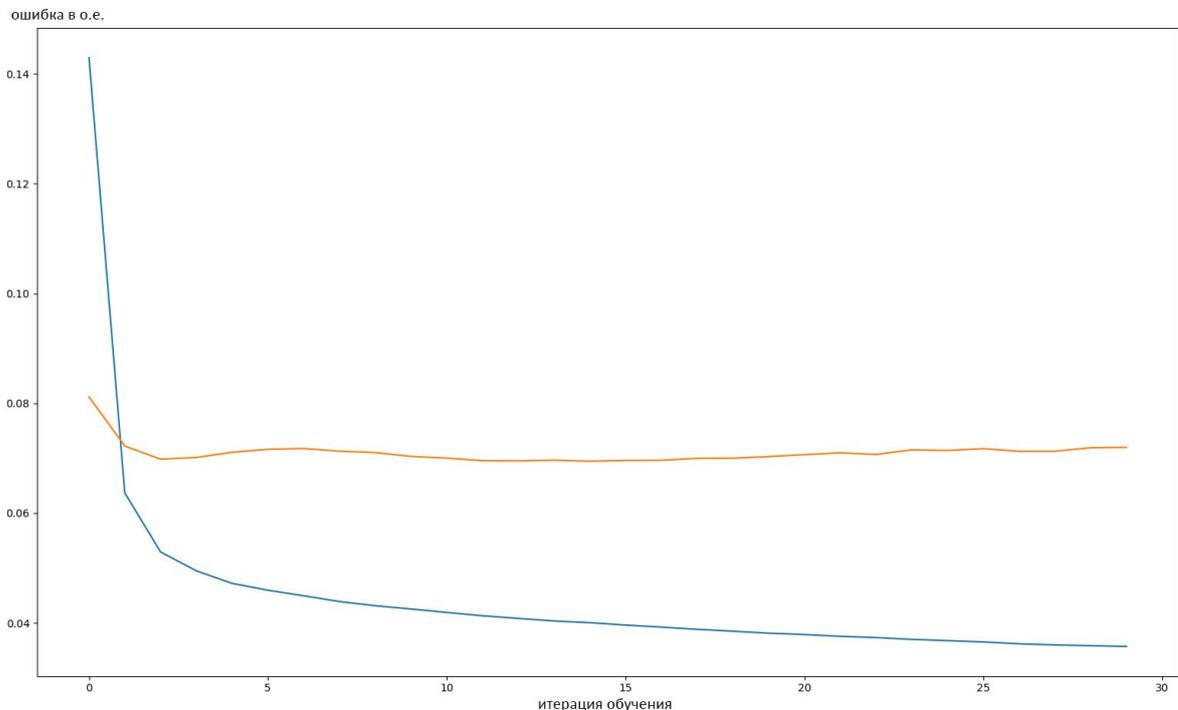


Рис. 2.20 – Ошибки обучения НАС.

Результаты обучения и прогнозирования с помощью нейро-аналитической сети, представлены на Рис. 2.20 и Рис. 2.21. Время обучения на выборке режимов в

1 месяц составила 39 минут. Тестирование обученной модели проводилось на диапазоне данных объемом 10% от обучающей выборки, располагаемых непосредственно следом за обучающей выборкой. Среднеквадратичное отклонение по всем прогнозируемым параметрам равнялось 0,0836. Среднее абсолютное отклонение при этом составило 0,191. При этом все параметры были выражены в относительных единицах.

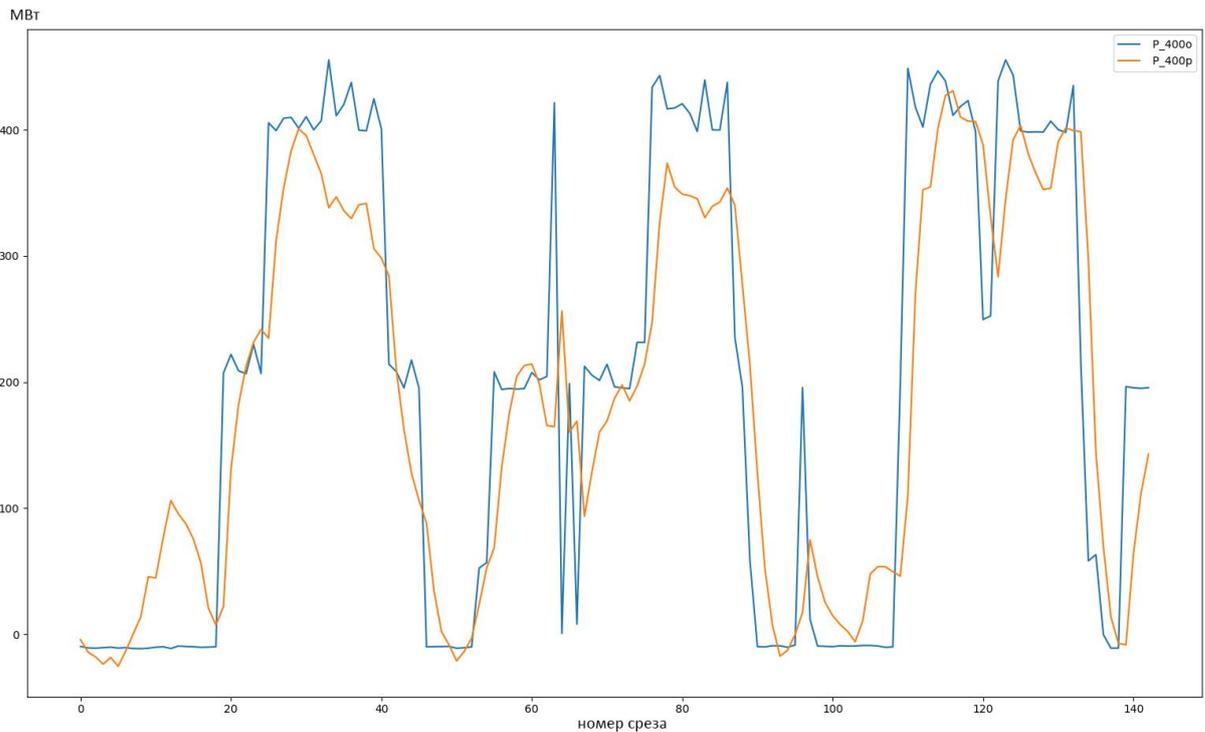


Рис. 2.21 – Результаты прогнозирования с помощью НАС.

Полученные с помощью нейро-аналитической сети прогнозы вполне достаточны для проведения динамической оптимизации.

2.7 Выводы по главе 2

1. Классические методы динамического оценивания состояния, основанные на модификациях фильтрах Калмана, ограничены в применении в современных энергосистемах с получением данных от SCADA-систем. Методы фильтрации могут применяться в основном для таких задач, как:
 - Автоматическое управление работой энергоустановок.
 - Адаптивное управление активной нагрузкой и ВИЭ, например, для таких задач как оптимальное управление накопителями и т.д.

2. Анализ динамического поведения энергосистемы с использованием эргодической теорией динамического хаоса показывает, что для краткосрочного прогнозирования поведения системы глубина анализируемого ретроспективного набора данных должна быть не менее суток (для рассматриваемой энергосистемы). Данный вывод согласуется с тем, что данные нагрузки в энергосистеме повторяются в соответствии с суточными графиками нагрузки. Для прогнозирования режимов на сутки вперед требуется архив измерений глубиной не менее месяца.
3. Глубокие ИНС на основе ячеек LSTM позволяют адекватно прогнозировать изменение параметров режима в том случае, если количество прогнозируемых параметров невелико. Для рассматриваемой реальной электрической сети количество параметров режима успешно прогнозируемых с помощью LSTM было не более 10-ти.
4. Измерения параметров электрического режима носят вероятностный характер. Так как дисперсии измеряемых величин, как правило, известны, то эту информацию можно использовать для обучения нейронной сети. Использование этой информации возможно за счет применения байесовских ИНС.
5. Для крупной энергосистемы прогнозирование минимально необходимого для расчета установившегося режима набора параметров с использованием LSTM сетей требует скрытых слоев большого объема, что не позволяет обучать такую сеть за приемлемое время.
6. Предложена архитектура искусственных нейро-аналитических сетей, которая позволяет выполнять прогнозирование электрического режима на полномасштабных схемах энергосистем в реальном времени и с приемлемой точностью.

ГЛАВА 3. ОПТИМИЗАЦИЯ РЕЖИМОВ ЭЛЕКТРИЧЕСКИХ СЕТЕЙ ПРИ ОПЕРАТИВНОМ И АВТОМАТИЧЕСКОМ УПРАВЛЕНИИ

В главе описывается постановка задачи оптимизации режимов электрических сетей при управлении на основе имеющегося прогноза изменения параметров электрических режимов. Далее показано применение существующих алгоритмов для динамической оптимизации и предложен новый алгоритм стохастической оптимизации, позволяющий решить задачу ведения оптимальных режимов для крупной энергосистемы. Сформулирована и решена задача динамической оптимизации с учетом вероятностного характера параметров электрического режима. Показана невыпуклость целевой функции статической оптимизации и предложен метод решения невыпуклой задачи статической оптимизации электрических режимов. Предложенные алгоритмы опробованы на примере реальной энергосистемы.

3.1 Архитектура системы оптимального управления ЭЭС

3.1.1 Описание модели верхнего уровня

Оптимизация на верхнем уровне представляет собой многоцелевую оптимизацию, которая может решаться различными методами, такими как: оптимум по Парето [189], минимизация расстояния до точки утопии [190], методы объединения в одноцелевую функцию. Среди объединяющих методов можно выделить такие, как: метод взвешенной суммы [191, 192], лексикографический метод [193], взвешенный минимаксный метод [194], экспоненциальный взвешенный критерий [195], метод взвешенного произведения [196], целевое программирование [197], физическое программирование [198].

Наиболее простым и достаточно эффективным способом является метод оптимизации взвешенной суммы, когда отдельные целевые функции суммируются в одну с помощью соответствующих весов.

$$f_{d_t}(x) = \sum_{i=1}^n w_i f_i(x, y) \quad \left| \begin{array}{l} b(x) \leq 0 \\ g(x, y) = 0 \end{array} \right. \quad (3.1)$$

где f_{d_t} – суммарная целевая функция для момента времени t ;

f_i – целевая функция по одному из рассматриваемых критериев;

$w_i \in \mathbb{R}$ – весовой коэффициент, соответствующий подзадаче целевой функции;

$x \in \mathbb{R}^d$ – вектор управляющих параметров, d – общее количество управляющих параметров;

y – параметры системы независимые от управляющих параметров x ;

$b(x)$ – ограничения, как на сами управляющие параметры, так и функциональные ограничения, определяющие системные режимные ограничения;

$g(x, y)$ – сетевые ограничения.

Использование весов позволяет гармонизировать отдельные составляющие целевой функции, масштабируя их таким образом, чтобы это максимально удовлетворяло целям сетевой компании. Рационализировать выбор весов позволяет метод анализа иерархий [199].

Составляющие целевой функции, входящие в задачу оптимизации верхнего уровня электрической сети [242]:

- 1) Минимизация стоимости генерации. В данной задаче она обозначает не столько стоимость производства энергии в энергосистеме, сколько минимизацию затрат на закупку электроэнергии у генерирующих компаний.

$$f_g(p_g) = \sum_{i \in G} (c_{i2} p_{gi}^2 + c_{i1} p_{gi} + c_{i0})$$

Управляющие параметры оптимизации: p_g – генерация активной мощности внутри сети или инъекция мощности в сеть из внешней питающей сети. G – множество генераторных узлов.

Приоритет учета и масштабирование параметров целевой функции задаются константами: c_{i2} , c_{i1} , c_{i0} – константы, масштабирующие учет стоимости генерации.

- 2) Минимизация потерь в электрической сети

$$f_{\Delta P}(U) = \sum_{\{i,j\} \in B} \Delta p_{ij}(U_i, U_j),$$

Δp_{ij} – потери в ветви $i-j$; U_i, U_j – напряжения в узлах смежных ветви, B – множество индексов узлов для каждой ветви в схеме замещения.

- 3) Уменьшение влияния на окружающую среду.

Функция эмиссии загрязнения может быть выражена как полиномиальная функция выходной активной мощности генератора следующим образом:

$$f_{\text{Pol}}(p_g) = \sum_{i \in G} e_{i0} + e_{i1} p_{gi} + e_{i2} p_{gi}^2 + \dots + e_{ik} p_{gi}^k,$$

где e_i – коэффициенты загрязнения, k – порядок.

В качестве ограничений на целевую функцию (3.1) выступают: ограничения на напряжение в узлах сети, инъекцию реактивной мощности в балансирующих по реактивной мощности узлах, ограничения на диапазон изменения управляющих параметров, а также, ограничения в виде баланса полной мощности в сети, определяемого как:

$$S_G - S_L - \Delta S = 0,$$

который, в свою очередь, вычисляется решением системы уравнений баланса мощности

$$S_N = \text{diag}(U) \cdot Y \cdot U^T \quad (3.2)$$

S_N – вектор инъекций мощности;

$U, \text{diag}(U)$ – вектор и диагональная матрица составляющих комплексов узловых напряжений;

Y – матрица комплексов проводимостей.

Управляющие параметры оптимизации x в (3.1) это:

- инъекции активной и реактивной мощности (для генераторов и компенсирующих устройств);
- напряжения в балансирующих по реактивной мощности узлах;
- коэффициенты трансформации ветвей;
- изменяемые проводимости ветвей (для устройств продольного регулирования);
- проводимости шунтов (для компенсирующих устройств).

Управляющие параметры представляются детерминированными величинами. Однако, ограничения на управляющие параметры могут представлять собой стохастическую величину. Так, например, располагаемый объем мощности генерации узла электрической сети с наличием возобновляемых источников генерации величина неопределенная и может быть оценена с некоторой вероятностью.

3.2 Динамическая оптимизация режима

В качестве исходных данных для оптимизации режима имеется прогноз изменения параметров режима на заданное время. Прогнозный горизонт разбит на отдельные временные срезы через равные промежутки. Каждый срез представляет собой минимально необходимый набор исходных данных для расчета установившегося режима, а именно:

- активные и реактивные мощности генерации;
- активные и реактивные мощности нагрузки;
- напряжения в балансирующих по реактивной мощности узлах;

- продольные и поперечные проводимости, изменяющиеся с течением времени;
- пределы изменения управляющих параметров;
- дисперсии инъекций мощности и замеров (прогнозов) напряжения.

Остальные параметры схемы замещения заданы для всех режимов и не меняются с течением времени.

Задачей динамической оптимизации является минимизация суммарной ЦФ на всем прогнозном временном горизонте за счет выбора состава и времени управляющих воздействий x_t для каждого момента времени прогнозного диапазона:

$$\min \sum_{t=0}^T f_t(\{x_0, \dots, x_t\}) \quad (3.3)$$

Под динамической оптимизацией понимается метод управления, при котором процесс не только поддерживается на оптимальном уровне в установившемся режиме, но и переход из одного режима в другой осуществляется наилучшим образом. При это не стоит путать динамическую оптимизацию с динамическим программированием [48], являющимся частным случаем динамической оптимизации при условии выполнения Марковских свойств динамической системой. Строго говоря, рассматриваемый процесс оптимизации (3.3) является квазидинамическим, так как вместо непрерывного закона изменения параметров системы мы имеем набор последовательных режимов через равные промежутки времени.

В отличие от статической оптимизации одного режима в задаче динамической оптимизации важно учитывать «стоимость» управляющих воздействий, которая зависит не только от вектора состояния системы, но и от времени. Под «стоимостью» управления здесь понимается абстрактная величина определяющая возможность и предпочтение использования того или иного управляющего воздействия в оптимизации. «Стоимость» управления тем или иным оборудованием зависит от таких факторов, как:

- остаточный ресурс оборудования;
- приоритет использования УВ;
- минимально допустимое время между коммутациями одним и тем же устройством.

Задача оптимизации (3.3) с учетом стоимости воздействия записывается, как:

$$\min \sum_{t=1}^T f_t(X_t, t) = \sum_{t=1}^T \left(f_{d_t}(X_t) + \sum_{i=1}^C f_{c_i}(x_{t_i}, t) \right) \left| \begin{array}{l} b(x) \geq 0 \\ g(x) = 0 \end{array} \right. \quad (3.4)$$

где X_t – управляющие воздействия доступные в момент времени t ; f_{d_t} – функция статической оптимизации каждого режима для времени t ; f_{c_i} – монотонно убывающая функция стоимости управляющего воздействия x_{t_i} , зависящая от времени воздействий, которые были выполнены до времени t ; $b(x)$ – ограничения на управляющие параметры; $g(x)$ – сетевые ограничения.

Примерный вид штрафной функции представлен выражением (3.5). Смысл данного выражения такой, что после применения управляющего воздействия повторное его применение в течение некоторого времени должно быть заблокировано высоким значением штрафной функции (Рис. 3.1). Через некоторое время стоимость воздействия снижается до постоянной величины c_i .

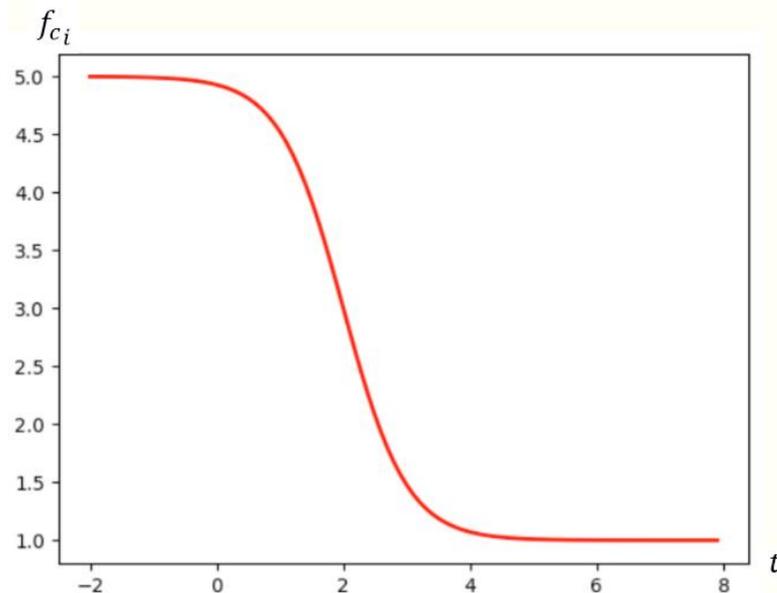


Рис. 3.1 – Пример функции стоимости управляющего воздействия

$$f_{c_i} = k_{c_i}(\text{th}(k_{d_i}(t_{p_i} - t + \Delta t_b)) + 1) + c_i \quad (3.5)$$

t_{p_i} – время, предыдущего применения данного управляющего воздействия.

$k_{c_i} > 0, k_{d_i} > 0, c_i \geq 0, \Delta t_b > 0$ – некие масштабирующие и сдвигающие константы.

Формула штрафной функции (3.5) позволяет обеспечить блокировку повторного использования данного воздействия с одновременным обеспечением гладкости целевой функции после применения данного воздействия.

Наличие в целевой функции зависимости от времени применения предыдущих управляющих воздействий делает процесс оптимизации не Марковским процессом. Так как «стоимости» воздействий и зависимости «стоимости» от времени для разных устройств различны (например, РПН трансформаторов переключать можно редко, а управлять с помощью УШР можно достаточно часто), то отстроиться от таких воздействий и вернуть процессу оптимизации Марковские свойства не получится.

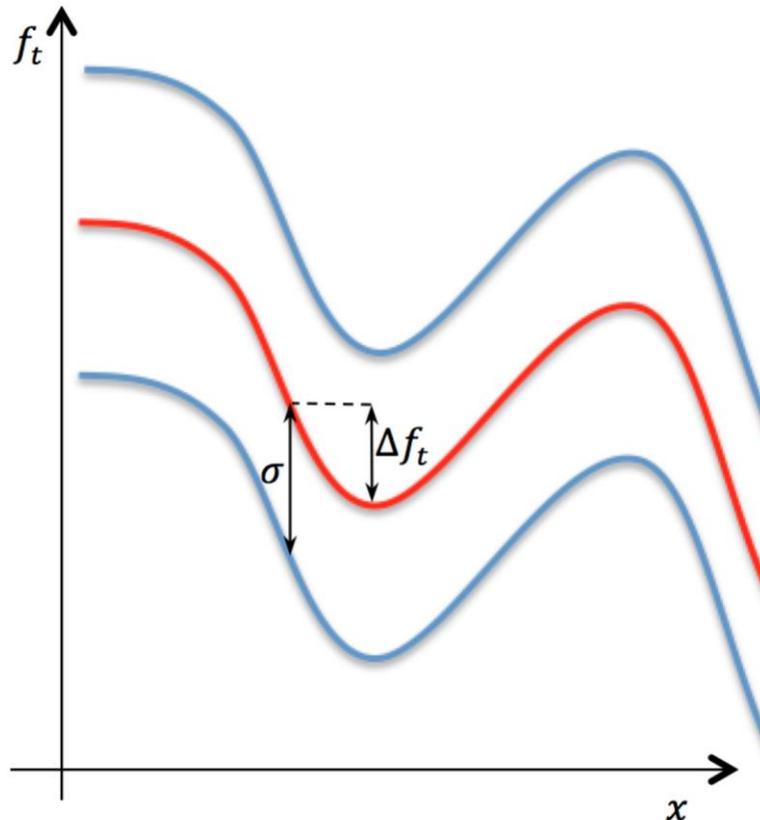


Рис. 3.2 – Влияние дисперсии целевой функции на процесс оптимизации

Дополнительную сложность вносит необходимость учета стохастичности исходных данных. Величина дисперсии целевой функции σ может быть больше чем улучшение величины целевой функции в процессе оптимизации Δf_t (Рис. 3.2). В предельном случае, если величина неопределенности целевой функции такая, что она может практически равновероятно принимать любое значение из допустимого диапазона, то оптимизировать такой режим смысла не имеет.

Для определения эффективной методики решения данной задачи динамической оптимизации разобьем ее на подзадачи, приняв некоторые допущения, а затем обобщим ее до исходной задачи. Так, на первом этапе решим задачу в детерминированной постановке. Потом уже введем в задачу стохастические параметры.

3.3 Детерминированная постановка задачи динамической оптимизации

В рамках данного раздела сформулируем минимальную модель и пример исходных данных адекватно отражающие задачу динамической оптимизации электрических режимов.

Задача автоматического оптимального управления электрическим режимом может быть достаточно упрощённо, но вполне адекватно представлена следующей моделью.

3.3.1 Модель динамической оптимизации ЭЭС

Есть прогноз изменения режима на некоторое время вперед. Время представляет собой набор срезов, то есть дискретно.

Задачей оптимизации является минимизация целевой функции, представляющей собой сумму целевых функций для каждого дискретного момента времени.

$$\min \sum_{t=1}^T \left(f_{dt}(S_t, Y_t) + \sum_{i=1}^{n-1} \sum_{j=i+1}^n f_{cij}(t) \right) \quad (3.6)$$

где S_t вектор инъекций мощности для t -го момента времени.

Y_t – матрица проводимостей ветвей, элементы которой (y_{tij}) и являются управляющими воздействиями.

f_{cij} – монотонно убывающая функция стоимости управляющего воздействия y_{tij} , зависящая от воздействий, которые были выполнены до времени t .

$$f_{cij} = k_{cij}(th(t_{p_{ij}} - t + \Delta t_b) + 1) + c_{ij} \quad (3.7)$$

$t_{p_{ij}}$ – время, предыдущего изменения y_{tij} – элемента матрицы Y_t .

$k_{cij} > 0$, $c_{ij} \geq 0$, $\Delta t_b > 0$ – масштабирующие и сдвигающие коэффициенты.

3.3.2 Статическая оптимизация для каждого момента времени

Для каждого момента времени может быть сформулирована следующая задача оптимизации в детерминированной постановке:

$$\min arg f_{dt}(Y_t) = \sum_{i=1}^{n-1} \sum_{j=i+1}^n (u_i - u_j)^2 y_{ij} \quad \left| \begin{array}{l} diag(U) \cdot Y_t \cdot U^T = S_t \\ y_{ij} \in [y_{ij \min}; y_{ij \max}] \end{array} \right.$$

где u – элементы вектора U напряжений в узлах электрической сети.

Ограничения на изменение управляющих воздействий заданы в виде минимальных $y_{ij \min}$ и максимальных $y_{ij \max}$ границ. Причем, для проводимостей, не

являющихся управляющими параметрами оптимизации, минимальная и максимальная граница равны текущему значению проводимости ветви в схеме замещения.

3.3.3 Построение тестовой модели

Здесь приведем достаточно простые правила формирования тестовой модели без привязки к данным реальной энергосистемы.

Матрица Y_t – разреженная. Отношение количества ненулевых недиагональных элементов к общему количеству недиагональных элементов $\approx 1/100$.

Изменение S_t в зависимости от времени можно задать следующим образом:

$$\begin{aligned} S_0 &\sim U[-100; 100] \\ S_t &= S_{t-1} + \mathcal{N}(0, \sigma_S^2) \\ y_{ij \max}, y_{ij \min} &\in [0; 10] \end{aligned}$$

Доля ветвей, выступающих своими проводимостями в качестве управляющих параметров оптимизации, 5 – 10%.

Топология задается следующими ограничениями:

- $y_{ii} \neq 0; y_{ij} = y_{ji}$
- для каждого $i \in [1; n]$: $\sum_{j=1, j \neq i}^n y_{ij} > 0$ (полностью связанный граф).

3.4 Решение задачи динамической оптимизации в детерминированной постановке методом имитации отжига

Первым этапом динамической оптимизации предлагается оценить нижнюю границу оптимального решения и выделить из всего набора управляющих воздействий те, которые влияют на получение оптимального решения на рассматриваемом временном диапазоне.

Для получения нижней границы решения глобальной оптимизации для каждого момента времени решается задача статической оптимизации. При этом из целевой функции исключается составляющая штрафа, зависящая от времени. Задача оптимизации для каждого момента времени записывается как:

$$\min f_{l_t}(S_t, X_t) = f_{d_t}(S_t, X_t) + \sum_{i=1}^{n-1} \sum_{j=i+1}^n c_{ij}, \quad (3.8)$$

где f_{d_t} – функция статической оптимизации каждого режима для времени t ; c_{ij} – постоянная составляющая стоимости управляющего воздействия, S_t – вектор свобод-

ных параметров режима, достаточный для расчета установившегося режима (инъекции мощности напряжения в балансирующих узлах), X_t – управляющие воздействия доступные в момент времени t .

В результате расчета для каждого момента времени $f_{l_t} < f_t$. Суммарная целевая функция для всего диапазона времени $[1 \dots T]$ также будет меньше, чем при учете составляющих стоимости воздействий, зависящих от времени.

Если количество срезов большое, например, из-за частой дискретизации времени, то уменьшить время расчета можно, выполняя расчет только при значительном изменении режима. Оценка значительности изменения режима может быть произведена по суммарному отклонению напряжения.

$$\sum_{i=1}^n |u_{p_i} - u_i| > \epsilon,$$

где u_{p_i} – напряжение в предыдущем режиме который был оптимизирован, u_i – текущий режим, ϵ – отклонение режима, выше которого производится оптимизация.

Управляющие воздействия, которые поменяли свое состояние в ходе оптимизации, составляют вектор $\xi = \bigcup_{t=1}^T \xi_t \in \bigcup_{t=1}^T X_t$.

Дальнейшее решение глобальной оптимизации на прогнозном интервале можно выполнить с помощью метода стохастической оптимизации, например, методом имитации отжига [209] от начального состояния, определяемого набором состояний $[\xi_1 \dots \xi_D]$. D – размерность вектора, соответствует количеству уникальных состояний, возникших в процессе статической оптимизации на исследуемом диапазоне времени. При этом возможны два варианта оптимизации. В первом варианте варьируется только время применения вектора управляющих воздействий ξ_i . При этом воздействия рассматриваются не индивидуально, а в виде вектора состояния, вычисленного в каждый момент времени t . Во втором случае варьируется не только время применения определенного набора УВ, но и его состав, начиная от вычисленного набора.

В качестве метода имитации отжига применяется адаптивный вариант сверхбыстрого отжига [210]. В качестве вектора управляющих воздействий принимаются времена применения набора состояния $[t_{\xi_1} \dots t_{\xi_D}]$, где $t_{\xi_i} \in [t_{i \min}, t_{i \max}]$. $t_{i \min} = t_{i_{k-1}}$ – соответствует начальному времени предыдущего состояния.

$t_{i \max} = t_{i_{k+1}}$ – соответствует начальному времени следующего состояния. Для первого и последнего состояния управляющих воздействий начальная и конечная граница соответствуют началу и концу исследуемого диапазона, соответственно.

В методе сверхбыстрого отжига для каждого оптимизируемого параметра используется собственное значение температуры. Адаптация сверхбыстрого отжига для исследуемой задачи заключается в адаптации температуры по каждому из измерений. Чем больше целевая функция зависит от конкретного параметра, тем медленнее снижается температура по этому измерению.

$$\delta_i = \left| \frac{f_c(x_i) - f_c(x_{i \min})}{x_i - x_{i \min}} \right|.$$

$$\delta_{\max} = \max[\delta_i]_D$$

Температура для каждой размерности изменяется следующим образом:

$$T'_i := T_i k_i \frac{\delta_{\max}}{\delta_i},$$

$$k'_i := \left(\frac{\ln \frac{T_{i0}}{T'_i}}{K_t} \right)^D.$$

Описанный способ глобальной оптимизации режима на исследуемом интервале времени позволяет получить оптимальный режим просто перемещением наборов управляющих воздействий по оси времени без изменения их состава (Рис. 3.3).



Рис. 3.3 – Оптимизация времени применения набора воздействий

Такой подход применим при достаточно плавных или однонаправленных изменениях исходных данных (вектора состояния режима S_t). Однако, возможны случаи, когда режим меняется таким образом, что при высоких значениях составляющих целевой функции, зависящих от времени (первый член в выражении 3.7), требуется изменение одних и тех же управляющих воздействий. В этом случае для достижения общего оптимума на всем временном диапазоне может потребоваться изменение состава управляющих воздействий. Отличием применения адаптивного варианта сверхбыстрого отжига в этом случае будет то, что параметрами оптимизации будут не времена применения заранее вычисленных воздействий, а сами

управляющие параметры в каждый момент времени (даже те, которые не менялись).

$$X = [X_t]_{1..T}$$

Длина вектора при этом будет равной $n \cdot T$, где n – количество управляющих параметров, участвующих в оптимизации.

Начальное состояние вектора X соответствует решениям, найденным в ходе решения набора задач статической оптимизации для каждого момента времени.

Несмотря на то, что во втором варианте размерность задачи увеличивается по сравнению с первым вариантом, решение получается более универсальным. Механизм адаптации при этом позволит быстрее остановить изменения тех параметров, которые слабо влияют на целевую функцию и тем самым уменьшить влияние размерности задачи на общее время расчета. Однако, несмотря на это, при достаточно большом количестве управляемых параметров часто возникают ситуации, когда в процессе поиска оптимального набора управляющих воздействий и их распределения во времени алгоритм имитации отжига отходит от оптимальной траектории управления и уже больше не сходится.

Проблемой применения существующих стохастических алгоритмов оптимизации, таких как метод имитации отжига или роя частиц для решения задачи динамической оптимизации режимов является поиск оптимума по всему пространству параметров оптимизации, одним из измерений которого является время. При этом мы имеем нижнюю границу целевой функции (3.8) для каждого момента времени, определяемую по результатам статической оптимизации и для большинства моментов времени в процессе оптимального управления слагаемое в целевой функции, зависящее от времени (Рис. 3.1) близко к нулю. Для использования этой особенности динамической оптимизации электрических режимов был разработан специальный алгоритм стохастической оптимизации.

3.5 Предлагаемый алгоритм динамической оптимизации

Автором разработан алгоритм стохастической оптимизации динамического процесса, позволяющий эффективно находить набор оптимальных воздействий с учетом составляющей целевой функции, зависящей от времени. Алгоритм основан на методе роя частиц [241].

Классический алгоритм оптимизации методом роя частиц (Particle Swarm Optimization) заключается в следующем.

Создается рой частиц. Каждая частица представляет собой агента, представленного координатами в пространстве управляющих параметров и вектором скорости в этом пространстве. Каждая частица помнит координаты лучшего решения, найденного ей, а также знает координаты лучшего решения, найденного всем роем частиц.

Инициализация начальных координат и скоростей частиц производится случайным образом, обычно равномерно по всему объему пространства управляющих воздействий, ограниченного допустимыми пределами изменения параметров.

В процессе оптимизации скорость частицы изменяются по следующему алгоритму:

$$v_i(t + 1) = \omega v_i(t) + c_1 r_1 (y_i(t) - x_i(t)) + c_2 r_2 (g(t) - x_i(t)), \quad (3.9)$$

где

$v_i(t)$ – скорость i -ой частицы в момент времени t ,

ω – коэффициент инерции,

c_1 – коэффициент движения к локальному оптимуму,

c_2 – коэффициент движения к глобальному оптимуму,

$y_i(t)$ – координаты локального оптимума, найденного к моменту времени t ,

$g_i(t)$ – координаты глобального оптимума, найденного к моменту времени t ,

$r_1 \in [0; 1]$, $r_2 \in [0; 1]$ – случайные величины, получаемые на каждой итерации оптимизации.

Координата частицы в пространстве решений изменяется следующим образом:

$$x_i(t + 1) = x_i(t) + v_i(t)$$

Классический алгоритм роя частиц не решает проблем указанных в конце П. 3.4.

Автором предлагается новый алгоритм, основанный на алгоритме роя частиц, который решает задачу динамической оптимизации электрических режимов с большим количеством управляющих воздействий. Было принято рабочее название алгоритма – «Камень в реке» (River Stone - PSO). Смысл этого названия будет понятен на основе его дальнейшего описания.

Смысл алгоритма следующий. В процессе оптимизации мы двигаемся по оптимальной траектории, определяемой результатами статической оптимизации. Целевую функцию динамической оптимизации (3.6) можно переписать в виде

$$\min \sum_{t=1}^T (f_0(t) + \xi(t)) \quad (3.10)$$

где $f_0(t)$ – составляющая целевой функции в момент времени t не зависящая от воздействий выполненных в прошлые моменты времени ($t-i$) и получаемая в результате статической оптимизации электрического режима для каждого момента времени;

$\xi(t)$ – составляющая целевой функции зависящая от воздействий выполненных в прошлые моменты времени (3.5).

Если значение $\xi(t)$ на шаге оптимизации превышает некоторую пороговую величину $\xi(t) > \varepsilon$, то выделяется диапазон моментов времени (срез) для которых выполняется данное условие и для этого диапазона выполняется динамическая оптимизация предлагаемым алгоритмом. При этом верхним диапазоном в суммарной целевой функции принимается значение индекса времени e при котором значение $\xi(t)$ становится меньше ε .

$$\min \sum_{t=1}^e (f_0(t) + \xi(t))$$

После того, как выделен новый диапазон моментов времени, на котором требуется выполнить динамическую оптимизацию, создается рой частиц. В отличие от классического алгоритма роя частиц, частицы не генерируются по всему объему пространства решений, а создаются в текущей точке, определяемой результатами статической оптимизации в которой впервые возникло превышение $\xi(t) > \varepsilon$.

Начальная скорость каждой частицы задается случайным образом, но так, чтобы в измерении соответствующем времени составляющая скорости была отрицательна, то есть начальная скорость направлена обратно по времени.

Для направлений пространства поиска решений, соответствующих управляющим воздействиям начальная скорость задается, как:

$$v_{0i} \sim k_v [-1; 1]$$

Для направления пространства поиска решений, соответствующего времени начальная скорость задается, как:

$$v_{0i} \sim -k_v [0; 1]$$

В алгоритме изменения скорости для каждой частицы добавляется еще одна точка притяжения. Кроме оптимального значения найденного самой частицей и глобального оптимума, найденного всем роем частиц добавляется точка e , соответствующая концу диапазона $\xi(t) > \varepsilon$ и управляющим воздействиям полученным в результате статической оптимизации для момента времени e :

$$v_i(t+1) = \omega v_i(t) + c_l r_1 (y_i(t) - x_i(t)) + c_g r_2 (g(t) - x_i(t)) + c_e r_3 (y_e - x_i(t))$$

где y_e – координата соответствующая концу интервала $\xi(t) > \varepsilon$,

c_e – коэффициент движения к концу интервала,

r_1, r_2, r_3 – случайные величины получаемые на каждой итерации оптимизации.

Иллюстрация работы предлагаемого алгоритма показана на Рис. 3.4. Двигаясь по оптимальной траектории мы натываемся на высокое значение $\xi(t)$, «отскакиваем» от него назад по времени и находим оптимальную траекторию, огибающую высокие значения целевой функции, наподобие того, как река огибает камень лежащий в ее русле. Отсюда и происходит название алгоритма.

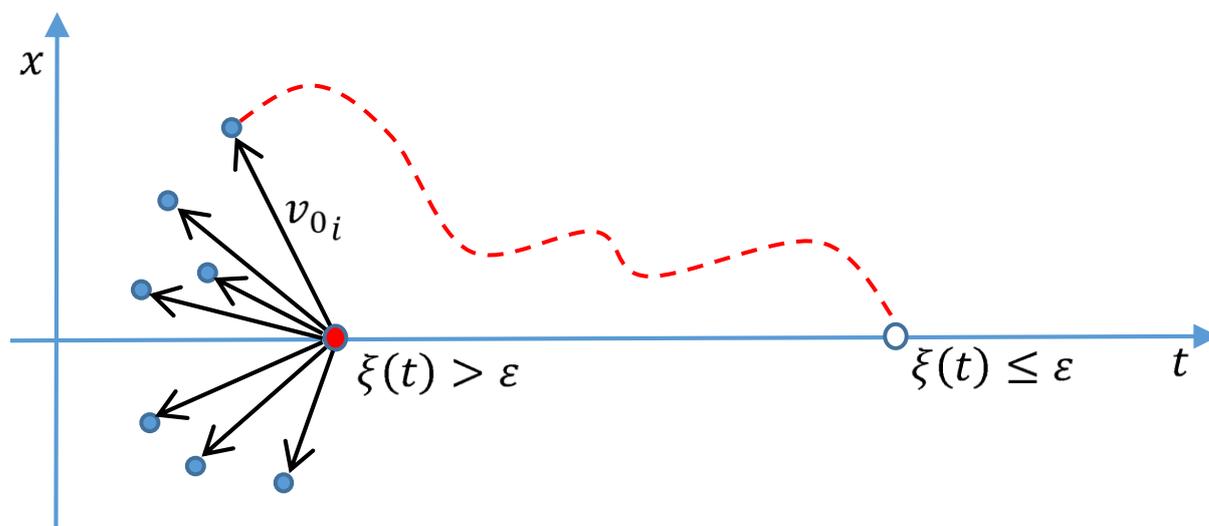


Рис. 3.4 – Иллюстрация работы алгоритма RS PSO

Предлагаемый алгоритм может быть использован не только для динамической оптимизации электрических режимов, но и для оптимального управления процессами, где стоимость управляющего воздействия зависит от прошлого времени его применения.

3.6 Особенности статической оптимизации в детерминированной постановке

3.6.1 О невыпуклости задачи оптимизации

Многие из современных методов оптимизации режимов основаны на необходимых условиях Каруша-Куна-Таккера, которые могут гарантировать только локальное оптимальное решение в свете невыпуклости задачи оптимизации режима ЭЭС [211, 212]. Невыпуклость задачи оптимизации определяется с одной стороны нелинейной зависимостью от физических параметров (мощностей и напряжения), с другой стороны наличием ограничений на параметры режима.

В современных исследованиях большое внимание уделялось разработке эффективных с точки зрения производительности алгоритмов. Например, в работах

[213, 214] предлагаются нелинейные алгоритмы внутренней точки. В работах [215, 216] показано возникновение невыпуклости задачи оптимизации при учете границ устойчивости режима. В этом случае стабильность на каждой итерации оптимизации является дополнительным ограничением. В работах [213, 217] предлагается выпуклая релаксация для решения задачи оптимального потокораспределения. Однако, для схем больших размерностей данный подход может оказаться неприменимым.

Как показано в статье [213], проблема оптимизации режима ЭЭС является NP-трудной задачей. При этом целевая функция обычно принимается выпуклой [213, 218]. В большинстве работ считается, что невыпуклость задачи оптимального потокораспределения возникает только из-за необходимости учета ограничений на параметры режима.

В рамках данной работы было проведено исследование указанного допущения. Был проведен поиск локального оптимума для реальной сложноразветвленной сети, начиная от различных случайно полученных начальных состояний в рамках допустимой области существования режима.

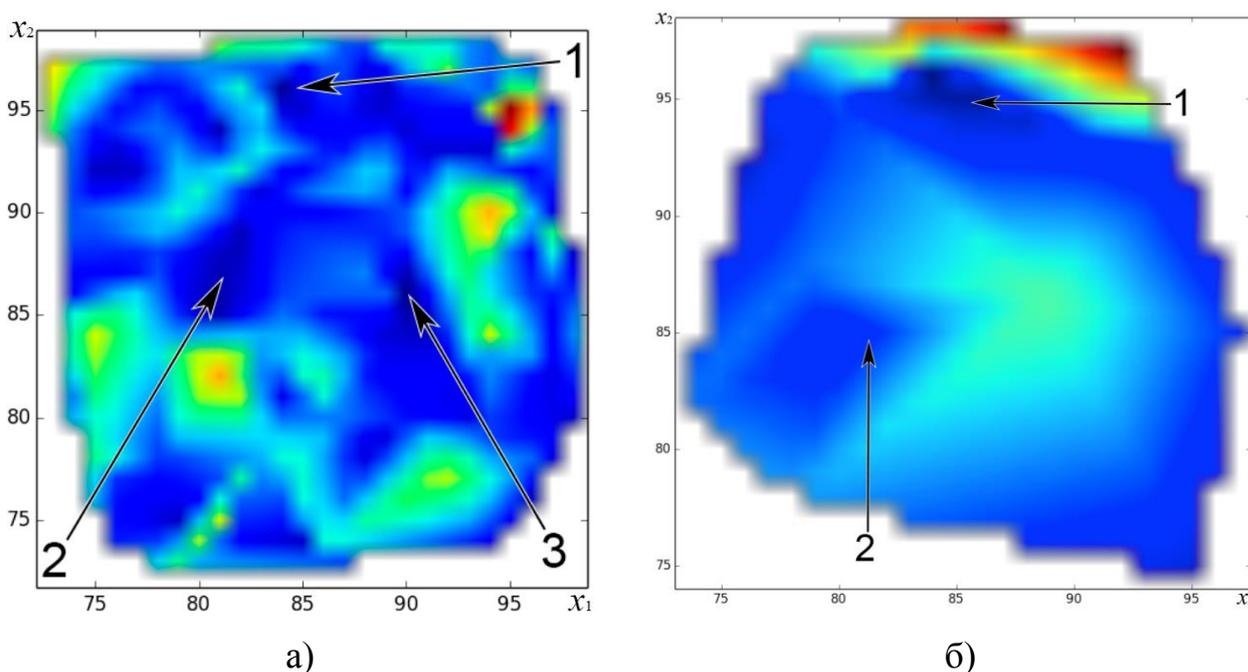


Рис. 3.5 – Значения целевой функции, показанные интенсивностью цвета (цифрами обозначены области локальных оптимумов): а) для случайного поиска без оптимизации; б) с последующей оптимизацией.

Расчет проводился на модели Иркутской энергосистемы (Рис. 2.13). В качестве управляющих параметров рассматривались только коэффициенты трансформации. Даже в таком упрощенном случае наблюдалась невыпуклость целевой

функции. На каждой итерации случайного поиска выбирались случайные значения управляющих параметров из допустимой области. После чего выполнялся расчет потокораспределения, в случае успешной сходимости которого, результаты сохранялись. Также от каждой точки случайного поиска выполнялся поиск локального оптимума методом градиентного спуска.

В результате расчетов получены значения целевой функции в n -мерном пространстве управляющих параметров, где n – количество управляющих параметров. Для наглядности на Рис. 3.5 приведены значения целевой функции в сечении двух наиболее изменяющихся управляющих параметров (x_1, x_2). В результате расчетов выявлено присутствие нескольких локальных оптимумов.

3.6.2 Поиск глобального оптимума при статической оптимизации

Для получения глобального оптимума (в рамках одного временного среза) выполняется поиск областей локального оптимума с помощью стохастического алгоритма глобальной оптимизации Липшецевой функции (LIPO), основанного на работе [219].

Если не рассматривать дискретные изменения режима, то задача оптимизации может считаться задачей оптимизации Липшицевой функции. В алгоритме AdaLIPO, представленном в [219], производится случайная выборка точек X_i из допустимой области управляющих параметров и по ближайшим точкам (Рис. 3.6) оценивается нижняя граница функции, используя коэффициент Липшицевости l .

$$x \rightarrow \max_{i=1..n} f(X_i) - l \cdot \|x - X_i\|_2. \quad (3.11)$$

Коэффициент l уточняется по значениям целевой функции как максимальный среди тестовых точек (N – множество тестовых точек).

$$l = \max_{i \in N, j \in N, i \neq j} \frac{|f(X_i) - f(X_j)|}{\|X_j - X_i\|_2}. \quad (3.12)$$

Для увеличения плотности тестовых точек в области с большим градиентом целевой функции и уменьшении количества испытаний в области с малыми значениями градиента автором был применен алгоритм случайного поиска с вероятностью, зависящей от величины градиента. Режим рассчитывается только в том случае, если случайная величина $p \in [0,1]$ меньше, чем относительная величина градиента

$$p_i < \frac{\|g_i\|}{\min_{i \in T} \|g_i\|}. \quad (3.13)$$

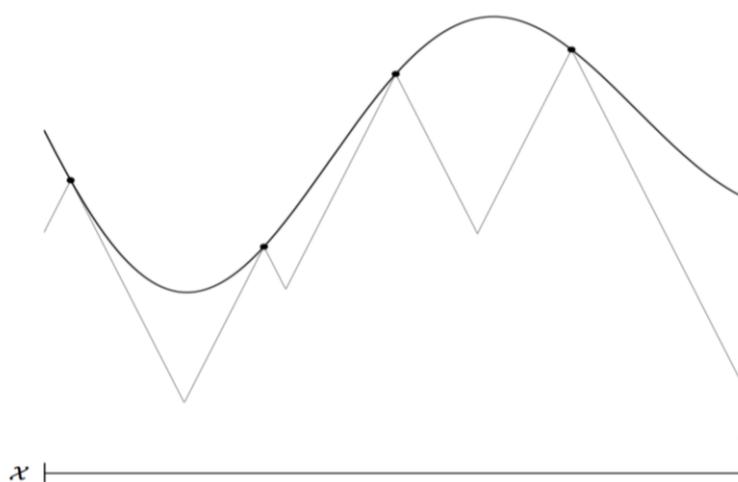


Рис. 3.6 – Иллюстрация работы алгоритма LPO.

Модификация алгоритма LPO, учитывающая градиент целевой функции по формуле (3.11) названа автором LIPOP (от слова probability).

Следует отметить, что поиск области оптимума целевой функции методом LIPOP не требуется выполнять для каждого момента времени динамической оптимизации. Распределение областей локального оптимумов целевой функции в пространстве управляющих параметров меняется только при значительных изменениях режима, определяемых коммутациями в сети (изменение топологии или подключение/отключение узлов нагрузки или генерации).

3.6.3 Решение выпуклой задачи статической оптимизации

Решение, полученное методом глобальной оптимизации может выступать, как начальное приближение для выполнения локальной оптимизации более точными методами. Таким образом, задача глобальной оптимизации режима электрической сети может решаться в два этапа. На первом этапе выполняется поиск области с наименьшим значением целевой функции глобальным поиском в допустимой области. На втором этапе решается задача поиска локального оптимума более точными методами.

В качестве метода поиска локального оптимума был применен квазиньютоновский метод, учитывающий ограничения на управляющие параметры L-BFGS-B [206, 220].

При этом учет ограничений на зависимые параметры режима выполняется в функции расчета потокораспределения на каждой итерации оптимизации при фиксированных значениях управляющих параметров. Таким образом, за счет декомпозиции задачи оптимизации на расчет потокораспределения и собственно задачу оп-

тимизации, с одной стороны, упрощается алгоритм оптимизации (ограничения становятся вида $l \leq x \leq u$), с другой стороны, в рамках процедуры расчета установившегося режима можно учитывать сложные модели элементов сети и модели автоматических систем управления (вставок постоянного тока (ВПТ), активных фильтров, компенсаторов реактивной мощности (СТК, STATCOM), гибких электропередач (FACTS), и других элементов, связанных с силовой электроникой).

Ограничения на параметры зависимого режима учитываются в виде барьерных функций, значения которых включаются в общую целевую функцию оптимизации и рассчитываются в процессе расчета потокораспределения на каждой итерации оптимизации. Логарифмические функции предлагается использовать в качестве барьерных функций по аналогии с методом внутренних точек:

$$F(x) = - \sum_{i=1}^m (-b_i(x)), \quad (3.14)$$

где $b_i(x) \leq 0, i = 1, \dots, m$ ограничения на зависимые параметры; m – количество ограничений.

Алгоритм поиска локального оптимума методом L-BFGS-B следующий.

1) На каждом шаге итерационного процесса мы имеем x_k – управляющий вектор, $f(x_k)$ – значение целевой функции, g_k – градиент целевой функции в точке x_k .

2) Для учета ограничений вида $l \leq x \leq u$ используется метод проекции градиента.

3) Квадратичная модель функции f записывается следующим образом:

$$m_k(x) = f(x_k) + g_k^T \cdot (x - x_k) + \frac{1}{2} (x - x_k)^T \cdot B_k \cdot (x - x_k), \quad (3.15)$$

где B_k – аппроксимация матрицы Гессе, полученная квазиньютоновском алгоритмом L-BFGS [221, 222].

Далее определяется кусочно-линейная функция, совпадающая по направлению с антиградиентом и учитывающая ограничения.

$$x(t) = P(x_k - t \cdot g_k, l, u),$$

где

$$P(x, l, u)_i = \begin{cases} l_i, & \text{если } x_i < l_i \\ x_i, & \text{если } x_i \in [l_i, u_i] \\ u_i, & \text{если } x_i > u_i \end{cases}.$$

После этого вычисляется локальный минимум модельной функции по выбранному кусочно-линейному направлению (Рис. 3.7), называемый в иностранной литературе точкой Коши.

$$x_c = \underset{x}{\operatorname{argmin}} m_k(x(t))$$

Итерационный процесс продолжается до тех пор пока изменение управляющего вектора вдоль направления оптимизации больше допустимой погрешности вычислений $\|x_k - x_{k-1}\| > \varepsilon$.

При движении по траектории оптимизации возможны ситуации, когда режим не сходится. В этом случае необходимо найти предельный режим вдоль данной траектории, при котором обеспечивается сходимость установившегося режима, и зафиксировать новые ограничения.

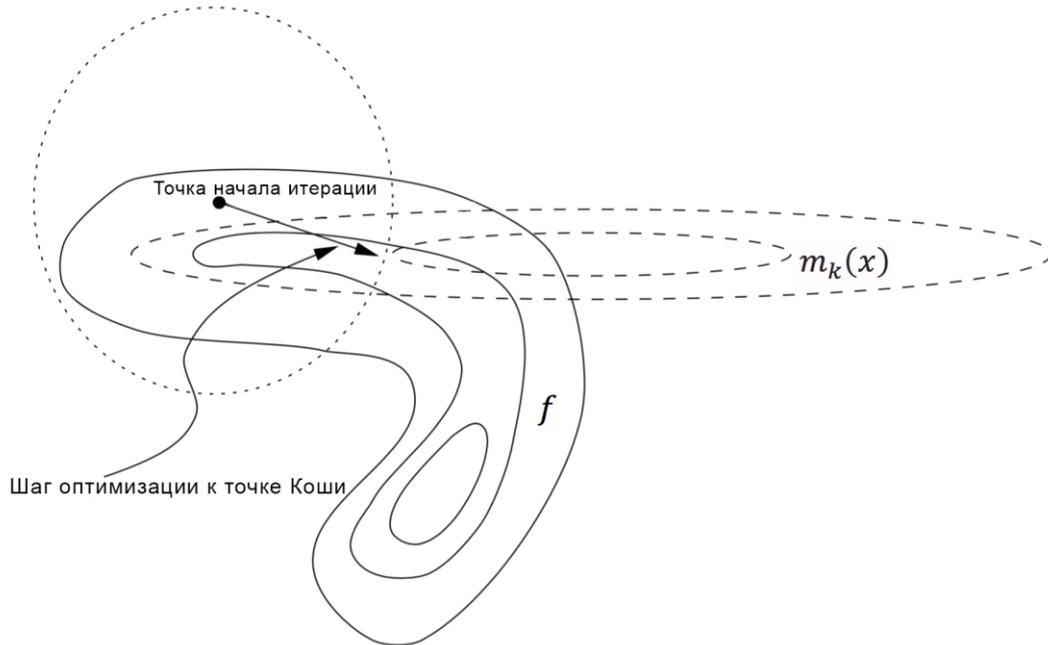


Рис. 3.7 – Движение по выбранному направлению в процессе оптимизации.

Движение вдоль траектории осуществляется методом деления пополам приращений вектора управляющих воздействий. Квадратичная модель (3.12) в этом случае записывается, как

$$m_k(x) = f(x_k) + g_k^T \cdot \Delta x + \frac{1}{2} \Delta x^T \cdot B_k \cdot \Delta x,$$

где

$$\Delta x = \frac{x - x_k}{2\alpha},$$

α – кратность деления шага.

3.6.4 Дискретные управляющие воздействия

Предложенная методика решения задачи статической оптимизации электрического режима эффективно работает для гладких целевых функций. Однако, целевая функция (3.8) имеет дискретную составляющую, определяемую стоимостью управляющего воздействия, как показано на Рис. 3.8. Действительно, при движе-

нии в пространстве управляющих воздействий по направлению, соответствующему определенному управляющему воздействию, в первый момент мы имеем «ступеньку» c_x в значении целевой функции. Дальнейшее движение по данному направлению уже соответствует гладкой функции.

Составляющая целевой функции $f_{d_t}(S_t, X_t)$ в (3.8), строго говоря, тоже дискретна (ступенчатая), так как устройства регулирования, такие как РПН изменяют свои параметры с определенным шагом. Для упрощения расчета дискретное представление $f_{d_t}(S_t, X_t)$ можно заменить на непрерывное и округлить оптимальное решение до ступеней регулирования управляющих устройств уже после завершения процесса оптимизации.

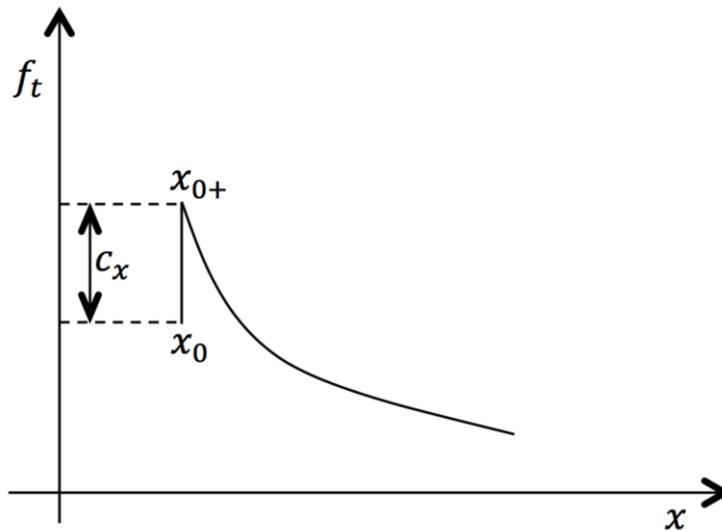


Рис. 3.8 – Дискретные изменения в целевой функции.

Что касается ступенчатых изменений функций, возникающих из-за ненулевой стоимости управляющих воздействий, то решением данной проблемы может быть применение субградиентов. Так, в статье [223] предлагается применение субградиентов с возмущениями при решении двойственной задачи Лагранжевой релаксации проблемы вида:

$$\min f(x) \mid g(x) + \delta \leq 0,$$

где под неопределенным заранее возмущением δ может пониматься, в том числе, дискретность изменения параметров и большая нуля стоимость управляющих воздействий. При этом шаг оптимизации задается постоянным, что не всегда применимо для методов, использующих субградиенты.

Более эффективный вариант оптимизации с использованием субградиентов – это субградиентная реализация квази-Ньютоновского метода BFGS, представленная

в работе [224] и названного subLBFGS. В субградиентной реализации BFGS отличия коснулись локальной квадратичной модели, нахождения направления спуска и нахождения размера шага, который подчиняется субградиентной переформулировке условий Вольфе.

3.7 Вероятностная постановка задачи

В вероятностной постановке целевая функция (3.1) может быть переписана как:

$$p(f_c(x)) = \sum_{i=1}^n w_i p_i(f_i(x)). \quad (3.16)$$

Вместо детерминированных составляющих целевой функции $f_i(x)$ здесь присутствуют распределения вероятности этих функций $p(f_i(x))$.

Как уже было показано выше, значения составляющих обобщенной целевой функции вычисляются на основе вектора состояния системы, представляющего собой напряжения в каждом узле электрической сети, а также значений мощности генерации. Распределение вероятности мощности генерации узлов, не являющимися балансирующими, может быть задано априорно в виде нормального распределения. Таким образом, вся сложность вычисления составляющих целевой функции сводится к вычислению распределения вероятности напряжений, которые, в свою очередь, могут быть получены из уравнений баланса мощности в электрической сети

3.7.1 Статическая оптимизация в вероятностной постановке

В вероятностной постановке баланс электрической мощности в сети (3.2) может быть записан, как:

$$p(S_N) = \text{diag}(p(V)) * Y * p(V)^t, \quad (3.17)$$

где $p(S_N)$ – вектор распределений вероятности инъекций мощности; $p(V)$ – искомые распределения вероятности вектора состояний системы.

В литературе такая постановка известна, как вероятностный расчет потокораспределения (Probabilistic Power Flow) и впервые предложена в [200]. Однако, при этом принимается допущение о линейности системы, пренебрегают потерями в сети, а также отсутствует зависимость между активной и реактивной мощностью. Такой подход допустим только для приближенного расчета балансов мощности в электрической сети. Развитие метода вероятностного расчета потокораспределения с тех пор продолжалось во множестве работ, таких как [201-203, 240].

Суть вероятностного расчета потокораспределения заключается в представлении уравнения баланса электрической мощности в вероятностной постановке (3.17) в линеаризованном виде:

$$p(S_N) = J^{-1}p(V), \quad (3.18)$$

где J – матрица Якоби текущего состояния системы.

В новых работах по данному направлению [202, 203] решается проблема вычислительной сложности операции свертки, которая может быть не применима для больших систем. Данная проблема решается аппроксимацией свертки полуинвариантами характеристической функции случайной величины. Однако, данные работы также основываются на допустимости о линейности решаемой задачи. Таким образом, данный подход может применяться или при планировании режимов энергосистемы, когда модель может быть упрощена до линейной или аппроксимация должна выполняться на каждой итерации решения нелинейной системы уравнений методом Ньютона, используя обновленные значения матрицы J .

В общем случае распределения вероятностей инъекций мощности могут быть разными для разных узлов.

Так, например, модель ветровой электростанции использует распределение Вейбулла [204] для определения вероятности скорости ветра, на основе которой рассчитывается распределение генерации ветровой электростанции. Распределение мощности солнечной электростанции рассчитывается с использованием функции бета-распределения, описывающей солнечную инсоляцию [205, 206].

Модель нагрузки обычно задается нормальным распределением со средним значением и стандартным отклонением. Что касается зарядной нагрузки EV, то она также может быть представлена нормальным распределением для каждого момента времени. При этом в течение суток ее математическое ожидание и дисперсия меняются. Распределение вероятности зарядной нагрузки в зависимости от времени при этом задается в виде логнормального распределения [24].

Значительно проще вычислять вероятностное потокораспределение можно в случае, если все инъекции в сети представлены нормальными распределениями. Распределение вероятности целевой функции для каждого момента времени в этом случае будет также представлять собой нормальное распределение. В этом случае видится обоснованным применение методов интервального анализа [207] для оценки распределения вероятности вектора состояний системы $p(V)$ и, как следствие, распределения вероятности целевой функции.

При использовании интервальной арифметики нормальное распределение вероятности инъекций мощности представляются в виде интервала

$$\mathbf{s}_i = [s_{0i} - \sigma_{si}^2, s_{0i} + \sigma_{si}^2].$$

Система уравнений баланса электрической мощности (3.17) при этом записывается в виде интервальной системы уравнений:

$$\mathbf{s} = \mathbf{v} \cdot \mathbf{Y} \cdot \mathbf{v}^t$$

\mathbf{s} – брус инъекций мощности;

\mathbf{v} – искомый брус переменных состояния системы.

Решение данной задачи может быть выполнено с помощью внешнего оценивания множеств решений интервальным методом Ньютона [208]. По значениям интервальных значений переменных состояния системы аппроксимируются математическое ожидание и дисперсии переменных состояний системы.

3.7.2 Динамическая оптимизация в вероятностной постановке

В вероятностной постановке целевая функция оптимизации для каждого момента времени задана распределением вероятности. С учетом того, что вектор свободных членов в системе уравнений баланса мощности задан нормальным распределением, то и распределение целевой функции будет нормальным. Задача динамической оптимизации (3.4) в вероятностной постановке записывается, как:

$$\min \sum_{t=1}^T \left(f_{d_t}(X_t) + \mathcal{N}(0, \sigma_{f_t}) + \sum_{i=1}^c f_{c_i}(x_{t_i}, t) \right), \quad (3.19)$$

где σ_{f_t} дисперсия целевой функции вычисленная для среза с временем t .

Также, как и при решении динамической оптимизации в детерминированной постановке предлагается применять разработанный автором метод RS PSO. В отличие от детерминированной постановки, при проверке необходимости фиксации текущего состояния, как глобального оптимума, значение целевой функции учитывается с допуском, определяемым дисперсией.

В обобщенном виде итоговый алгоритм динамической оптимизации выглядит следующим образом:

- 1) Результаты статической оптимизации каждого временного среза принимаются, как начальная траектория оптимального управления.
- 2) В случае если составляющая стоимости воздействия, зависящая от времени (3.6) больше минимального порога ε , выделяется соответствующий диапазон срезов и выполняется динамическая оптимизация на нем.
- 3) Генерируется рой частиц.
- 4) На каждой итерации оптимизации RS PSO для каждой частицы выполняются следующие действия:

- a) Выполняются изменения скорости и координат частицы в соответствии с алгоритмом RS PSO.
- b) Обновляются значения локальных и глобальных оптимумов.
- c) Если координата времени частицы превышает значение конца диапазона e , то частица уничтожается.
- d) Если суммарное значение целевой функции опускается до минимального с учетом допустимой ошибки ε и средней минимальной дисперсии целевой функции $\overline{\sigma}_{f_{min}}$, то поиск оптимума завершается.

3.8 Вычислительный эксперимент оптимизации

3.8.1 Статическая оптимизация.

Предлагаемые подходы к статической оптимизации были протестированы на схеме 118-узловой схеме IEEE (Рис. 3.9), и на схеме реальной энергосистемы на примере электрической сети Иркутской области (Рис. 2.13).

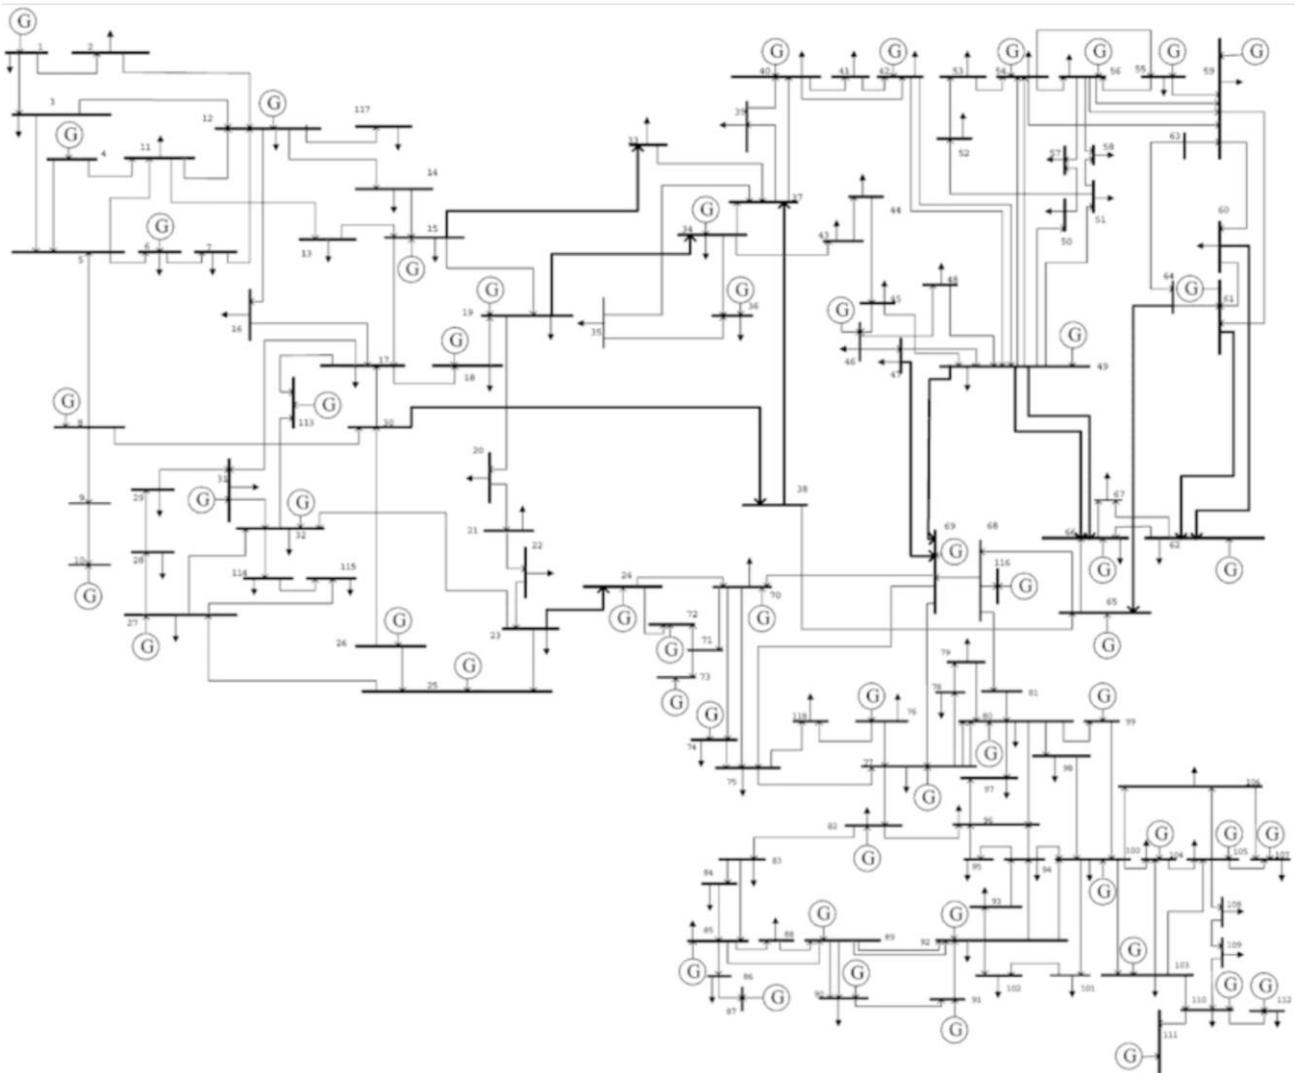


Рис. 3.9 – 118 узловая тестовая схема IEEE.

На данных тестовых примерах было выполнено по 10000 серий расчетов. В

качестве начальной точки оптимизации выбирались случайные значения управляющих параметров из допустимого диапазона. Результаты представлены на диаграммах. Ось ординат на диаграмме представляет значения целевой функции. Ось абсцисс соответствует серии расчетов, начинающихся от разных начальных состояний. На диаграммах обозначено: f_0 – начальные значения целевой функции в о.е.; fg – результат оптимизации градиентным методом; f_lbfgsb – результат оптимизации методом L-BFGS-B.

Результаты с хорошо выбранным шагом в методе оптимизации градиентного спуска на тестовой 118-узловой схеме IEEE достаточно близки к результатам алгоритма L-BFGS-B (Рис. 3.10), однако результаты расчета, полученные с использованием L-BFGS- В более стабильны (Рис. 3.11) и в среднем дают на 4% лучший результат (Рис. 3.12).

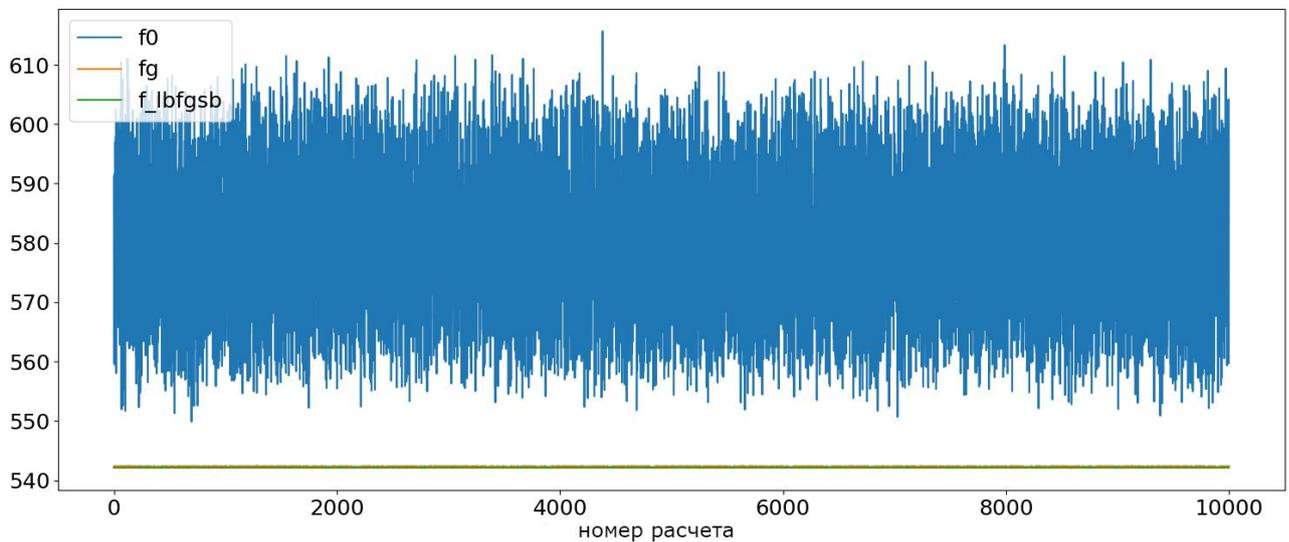


Рис. 3.10 – Начальные значения целевой функции и результаты расчета на 118-узловой схеме IEEE.

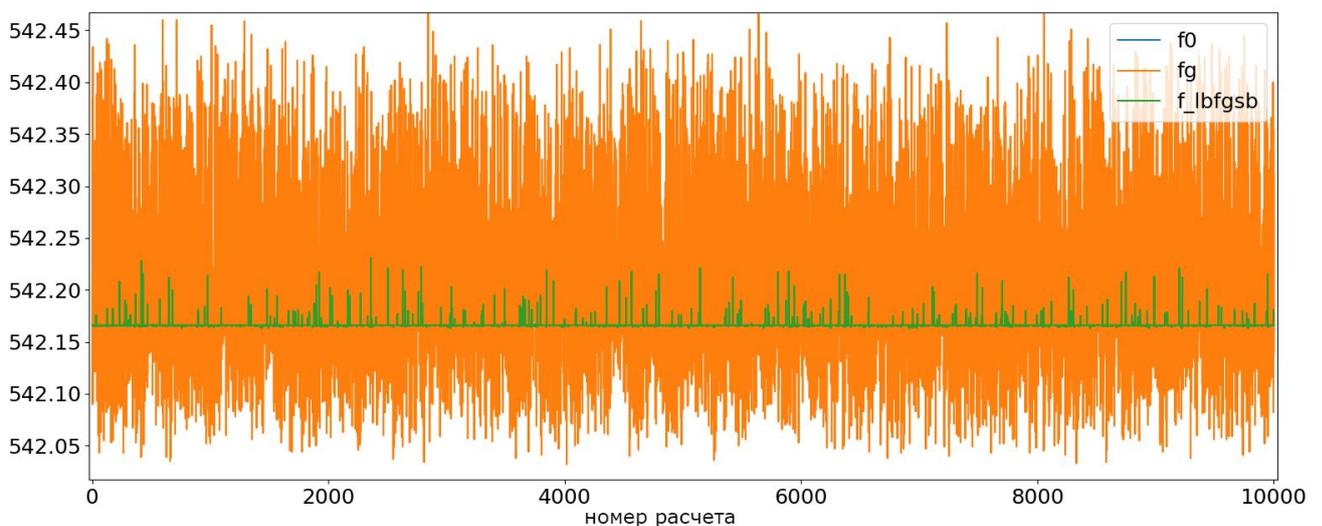


Рис. 3.11 – Результаты расчета на 118-узловой схеме IEEE.

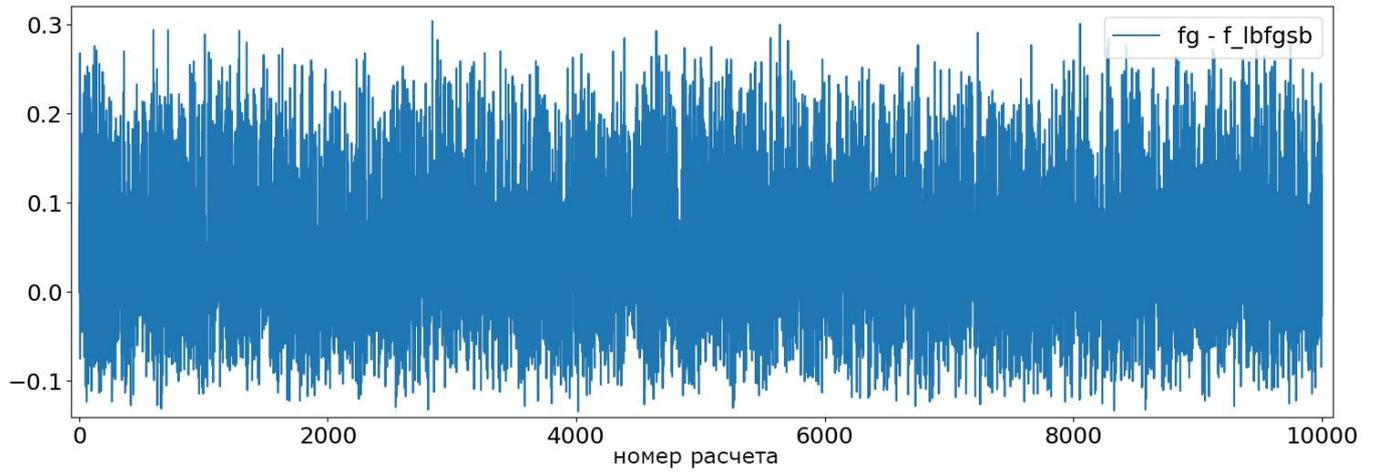


Рис. 3.12 – Разница между целевой функцией после градиентного спуска и L-BFGS-B.

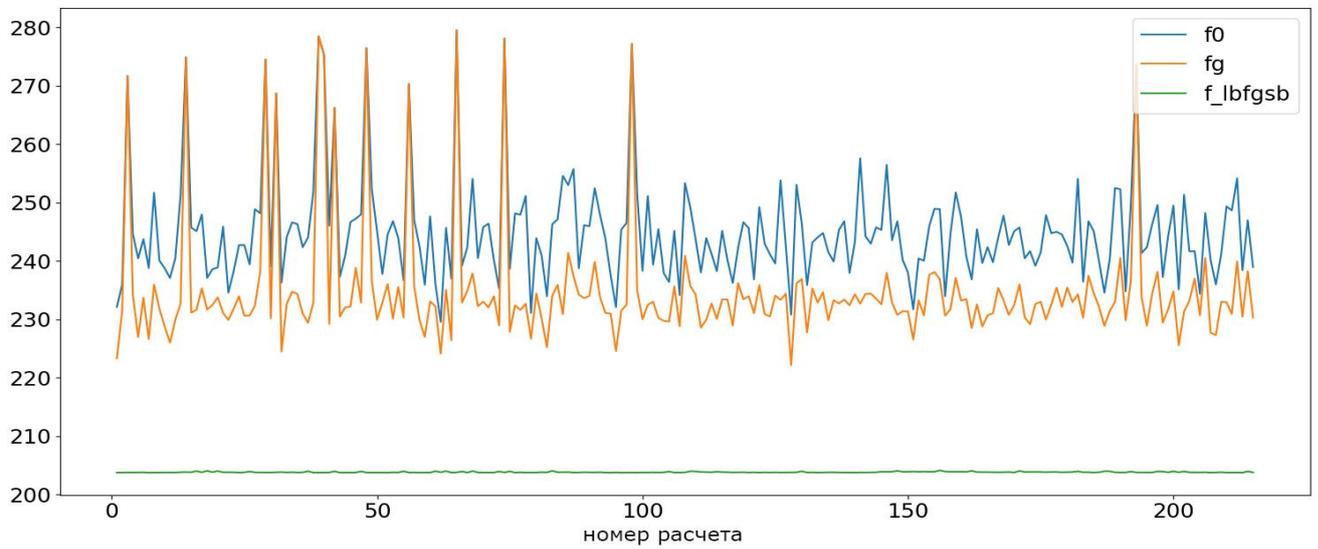


Рис. 3.13 – Результаты оптимизации на схеме ЭЭС Иркутской области.

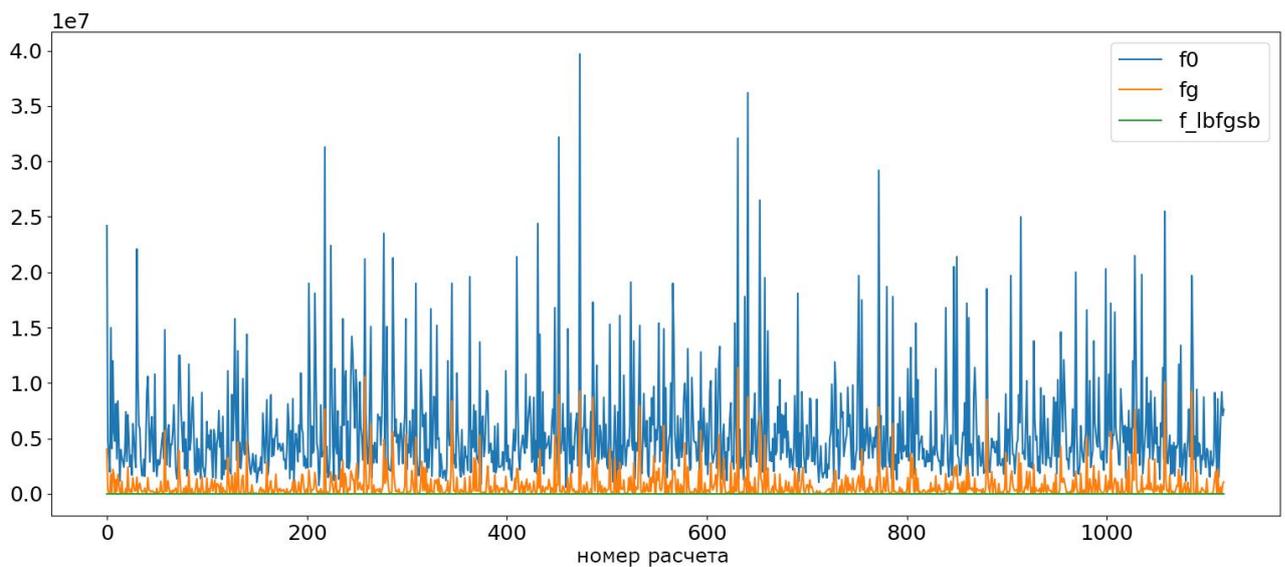


Рис. 3.14 – Результаты оптимизации на схеме ЭЭС Иркутской области с заданными ограничениями оптимизации.

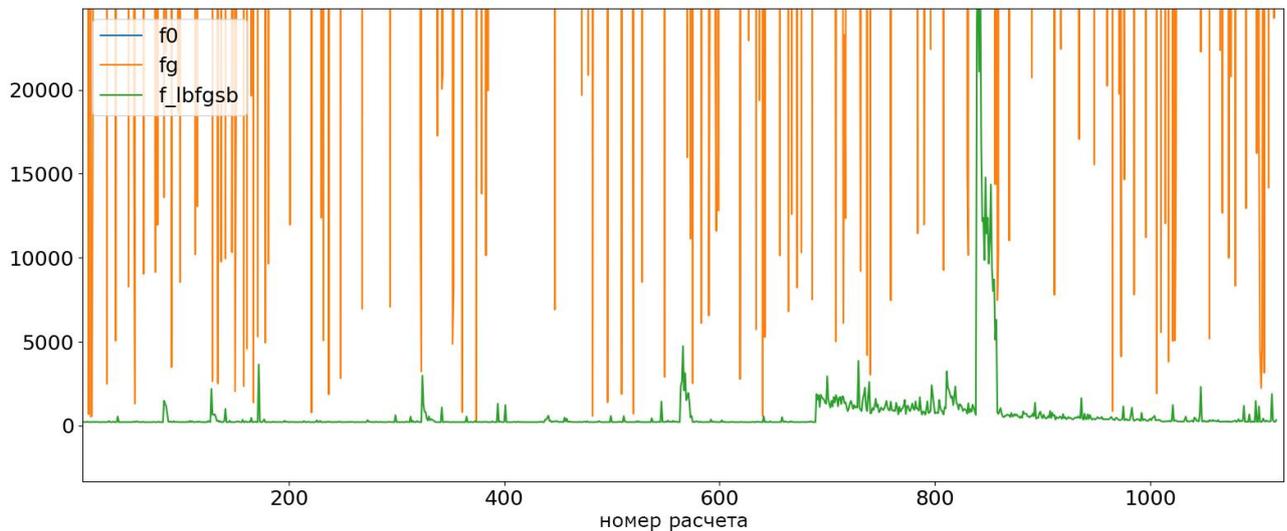


Рис. 3.15 – Результаты оптимизации на схеме ЭЭС Иркутской области с заданными ограничениями оптимизации в масштабе.

Более показательный результат наблюдается на модели реальных электрических сетей. Если оптимизация выполняется на модели без ограничений, результат алгоритма L-BFGS-B является стабильным и в несколько раз лучше, чем градиентный спуск (Рис. 3.13). Если алгоритм учитывает ограничения на напряжение на шине, применение алгоритма L-BFGS-B становится еще более эффективным (Рис. 3.14). На более крупномасштабном графике (Рис. 3.15) видно, что метод L-BFGS-B дает адекватные результаты с минимальной целевой функцией почти для всех начальных условий, в то время как градиентный спуск для большинства начальных состояний лишь незначительно улучшает целевую функцию относительно начальной (Рис. 3.15).

Эта разница в результатах может быть объяснена тем фактом, что расчет установившегося режима на модели реальной энергосистемы имеет худшую сходимость, а также градиентный спуск более чувствителен к начальному шагу. Скорости алгоритмов оптимизации сопоставимы. В схеме реальной электрической сети среднее время работы метода оптимизации градиента составляет около 120 мсек, а алгоритма L-BFGS-B - около 500 мсек.

3.8.2 Динамическая оптимизация.

В качестве примера для динамической оптимизации была выбрана модель реальной энергосистемы (Рис. 2.13), подготовленная в комплексе АНАРЭС [227]. Количество узлов в модели узлы/ветви для данной электрической сети – 1248 и количество ветвей – 1481. Количество элементов в сети значительно больше, так как

модель узлы/ветви формируется топологическим процессором, эквивалентирующим однолинейную схему электрической сети. Количество оптимизируемых параметров – 80. Количество пар граничных параметров типа $[x_{\min}; x_{\max}]$ – 1328. Стохастическое поведение энергосистемы эмулировалось заданием дисперсии для прогнозируемых инъекций мощности (нагрузки и генерации).

Для данной энергосистемы имелись архивные данные, представленные в виде набора рассчитанных электрических режимов с периодичностью в 30 минут. Глубина рассматриваемых архивов от одного месяца до одного года. При промышленном применении данного алгоритма оптимизация будет проводится на основе прогноза изменения параметров режима на определенный горизонт времени. Однако, для проверки самого алгоритма оптимизации архивных данных достаточно.

При оптимизации режимов на типовом архиве данных глубиной в месяц было выявлено 6 диапазонов, на которых проводилось динамическая оптимизация. Для каждого диапазона потребовалось не более 4-х итераций при 10-ти генерируемых частиц для каждого УВ (общее количество частиц 730). Результаты изменения целевой функции представлены на Рис. 3.16 – Рис. 3.21. На графиках f_c обозначает суммарное значение статической части целевой функции при текущем наборе управляющих воздействий, f_d обозначает полное суммарное значение целевой функции с учетом составляющей зависящей от времени.

На графиках видно, что в некоторых случаях статическая часть целевой функции увеличивается, что логично. При этом видно, что значение или строго, или значительно близко приближается к исходной минимальной границе целевой функции.

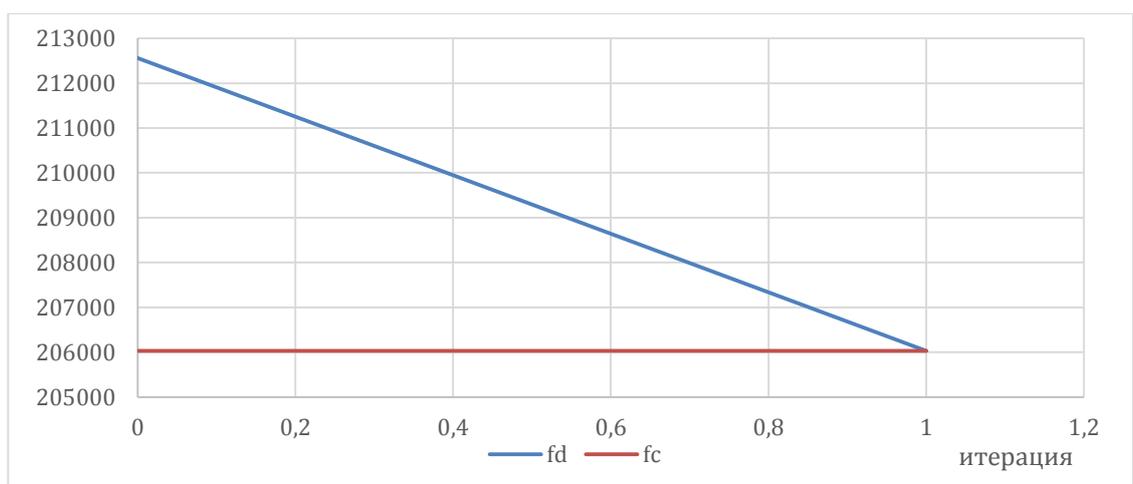


Рис. 3.16 – Изменение целевой функции в ходе динамической оптимизации RS PSO для 1-го диапазона.

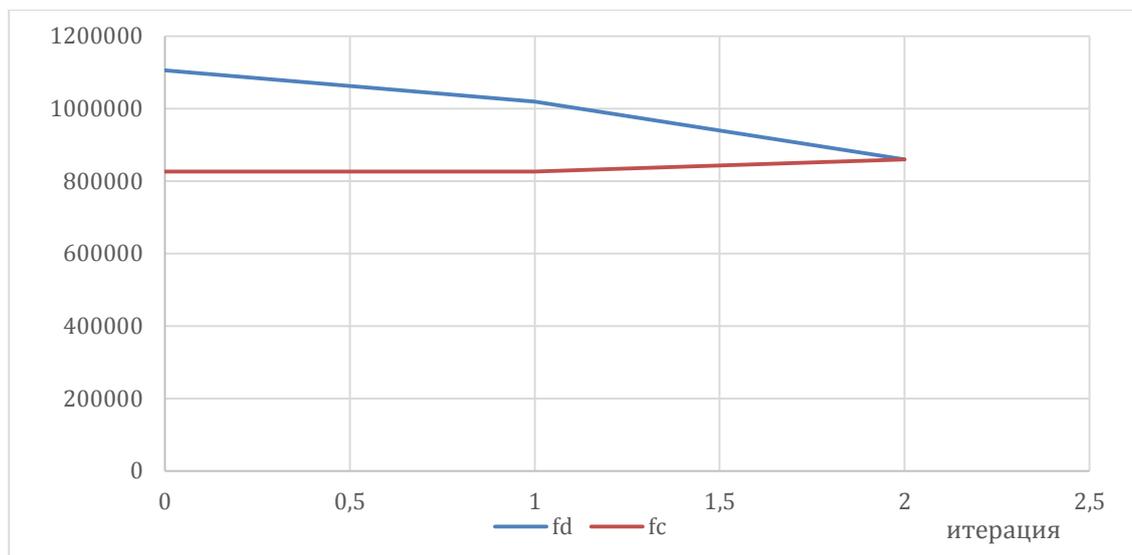


Рис. 3.17 – Изменение целевой функции в ходе динамической оптимизации RS PSO для 2-го диапазона.

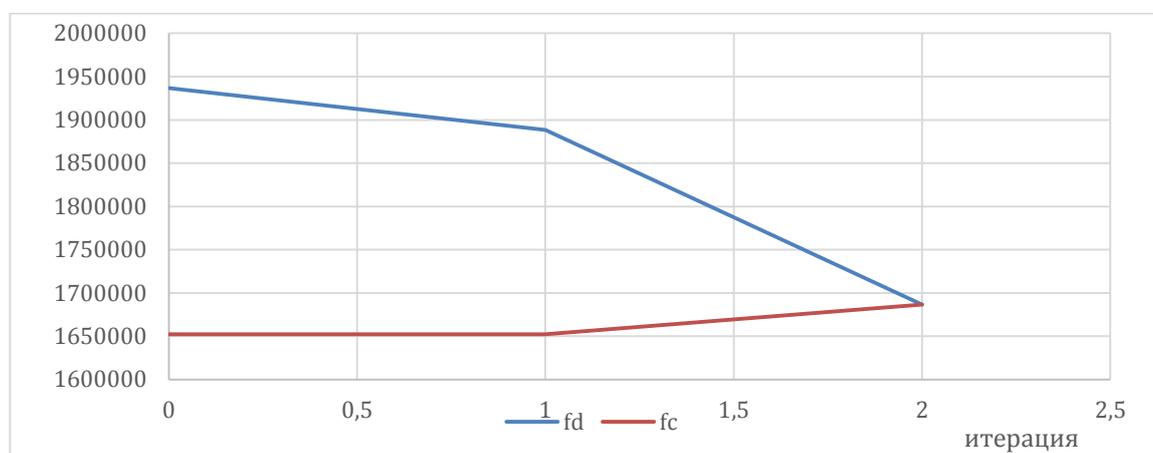


Рис. 3.18 – Изменение целевой функции в ходе динамической оптимизации RS PSO для 3-го диапазона.

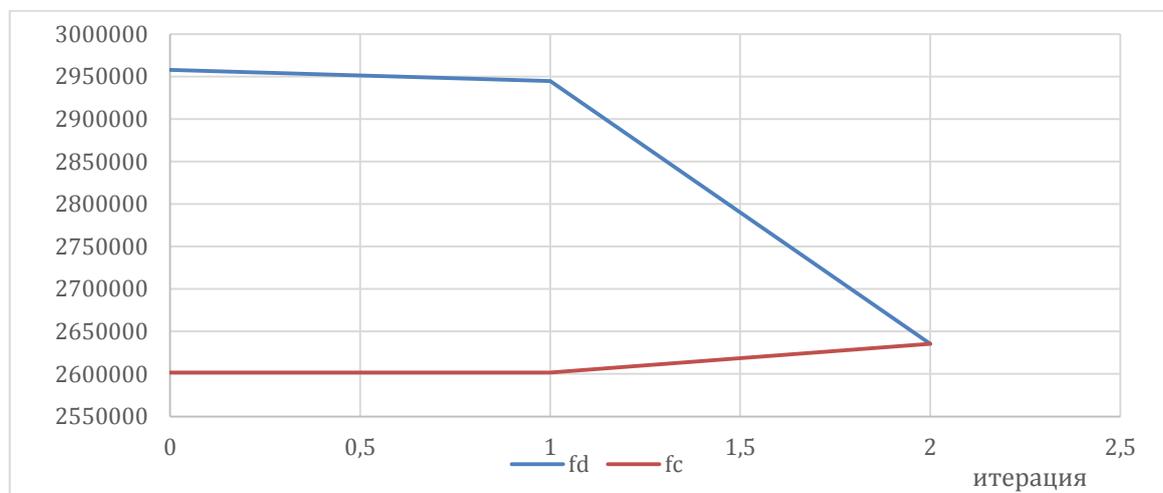


Рис. 3.19 – Изменение целевой функции в ходе динамической оптимизации RS PSO для 4-го диапазона.

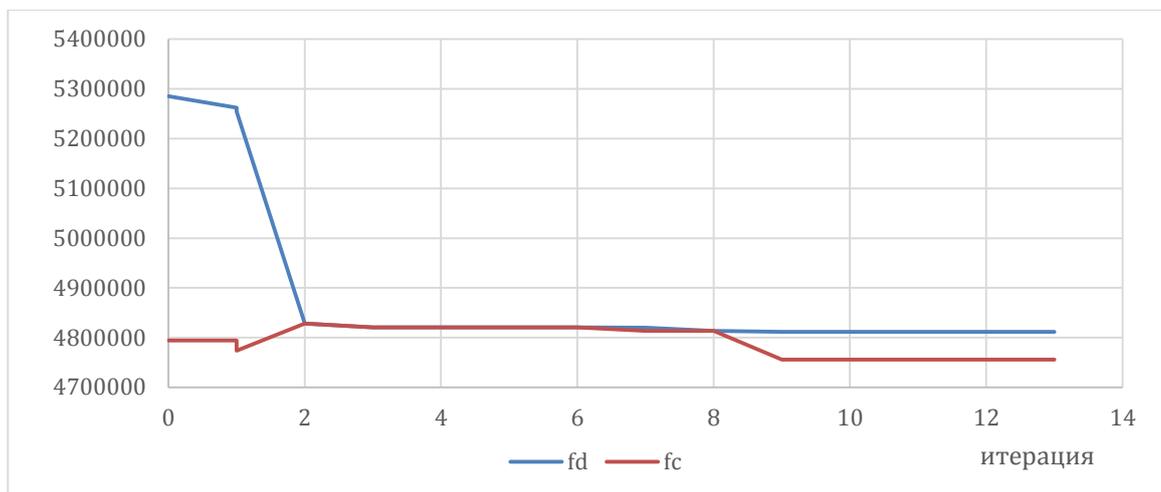


Рис. 3.20 – Изменение целевой функции в ходе динамической оптимизации RS PSO для 5-го диапазона.

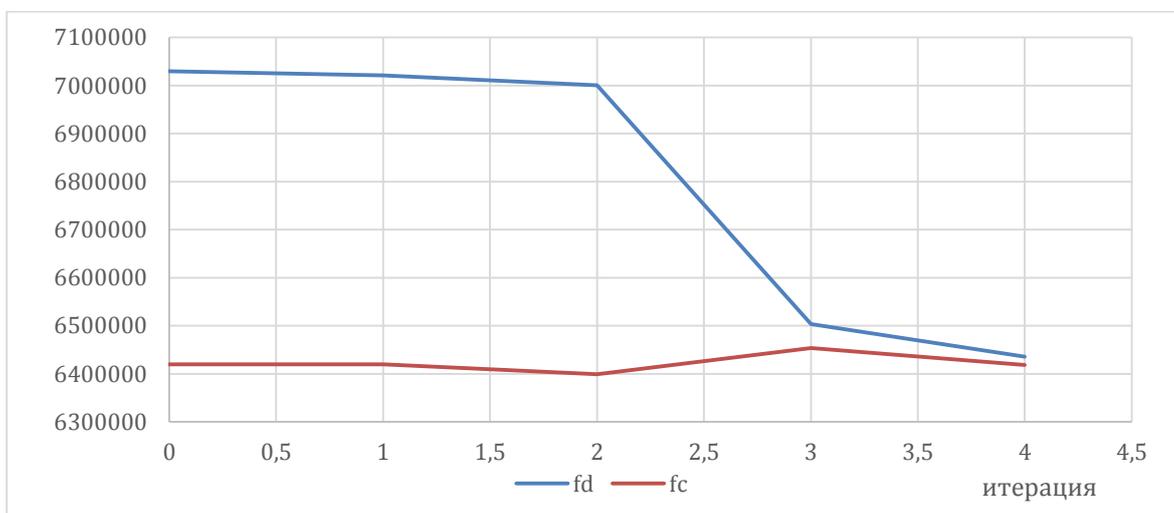


Рис. 3.21 – Изменение целевой функции в ходе динамической оптимизации RS PSO для 6-го диапазона.

Суммарные показатели уменьшения потерь и снижения отклонения напряжения в результате оптимизации за месяц с помощью предлагаемых методов приведены на Рис. 3.22. Суммарные показатели за год приведены на Рис. 3.23. Следует отметить, что входными данными являлись режимы, которые оптимизируются службой электрических режимов, на основе текущих и планируемых данных. Поэтому качество оптимизации предлагаемым методом по сравнению с используемыми в настоящее время можно оценить по приведенным суммарным показателям.

Из приведенных показателей видно, что суммарное уменьшение потерь электроэнергии за месяц, полученное в процессе динамической оптимизации, составило 31,21 МВт · ч. Суммарное уменьшение потерь в результате серии статических расчетов оптимизации для каждого временного среза составило 31,77 МВт · ч, что всего на 1,7 % лучше результатов динамической оптимизации. Таким образом, ре-

зультаты динамической оптимизации близки к теоретическому минимуму, полученному при условии, когда не учитывается стоимость управляющих воздействий. На некоторых диапазонах времени (Таблица 3.1) наблюдались нарушения заданных и используемых в сетевой компании ограничений напряжения, что привело к увеличению потерь электроэнергии в данные диапазоны времени.



Рис. 3.22 – Суммарное уменьшение потерь в результате оптимизации нарастающим итогом за месяц.

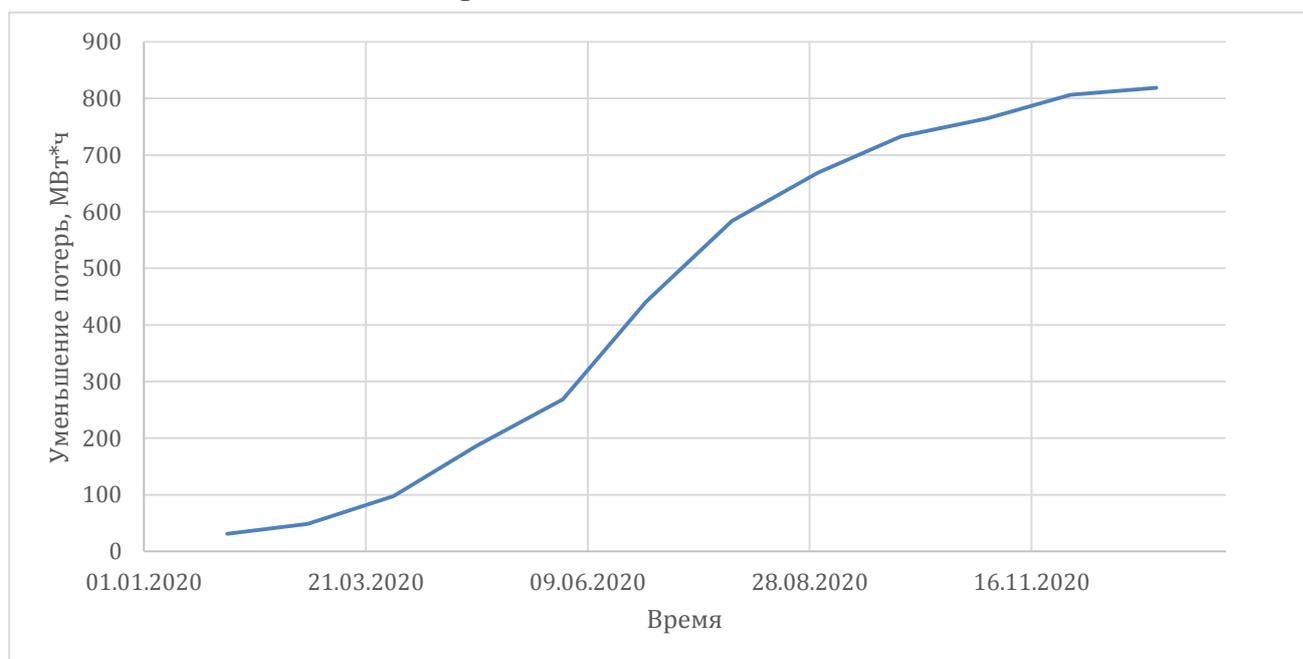


Рис. 3.23 – Суммарное уменьшение потерь в результате оптимизации нарастающим итогом за год.

Среднее уменьшение потерь электроэнергии за месяц, при выполнении динамической оптимизации в течение года, составило 68,2 МВт · ч. Суммарное уменьшение потерь электроэнергии за год составило 818,98 МВт · ч. Пример результатов расчета управляющих воздействий приведен в Приложении 2.

Таблица 3.1. Результаты оптимизации за месяц

Дата/время	Снижение потерь для одного среза времени, МВт*ч	Снижение отклонения U для одного среза времени, о.е.	Суммарное снижение потерь при динамической оптимизации, МВт*ч	Суммарное снижение потерь при статической оптимизации, МВт*ч
01.01.2020 0:00	0,0809094	-0,223199	0,0404547	0,0404547
01.01.2020 4:30	0,166209	-0,347498	0,417039	0,417039
02.01.2020 2:00	0,00846916	-0,531146	3,156	3,156
02.01.2020 3:00	0,155506	-0,324923	3,21029	3,21029
02.01.2020 12:30	0,149576	-0,330881	3,60229	3,677075
02.01.2020 21:00	0,162724	-0,342088	4,68891	4,763695
02.01.2020 22:00	0,206711	-0,394279	4,882735	4,957525
03.01.2020 10:30	0,00399124	-0,528108	5,9623	6,03905
03.01.2020 11:00	0,275015	-0,438006	6,0998	6,17655
03.01.2020 12:00	-0,239106	-0,542839	6,08795	6,16475
03.01.2020 12:30	-0,17185	-0,300979	6,002	6,0788
03.01.2020 13:00	0,119765	-0,316187	6,0619	6,1387
03.01.2020 19:00	0,237712	-0,419083	6,8428	6,91955
03.01.2020 21:30	0,0438761	-0,0605038	7,08585	7,16265
04.01.2020 11:30	0,16759	-0,344561	6,90995	7,07055
04.01.2020 20:00	0,312242	-0,507659	8,10945	8,27
04.01.2020 21:00	-0,22199	-0,387602	8,13795	8,29855
05.01.2020 10:30	0,0563544	-0,077541	8,61655	8,8053
05.01.2020 11:00	0,180537	-0,371879	8,7068	8,8956
05.01.2020 11:30	0,00795559	-0,273752	8,7108	8,89955
05.01.2020 12:30	0,151078	-0,343399	8,8667	9,05545
05.01.2020 13:00	0,13417	-0,315324	8,9338	9,12255
05.01.2020 19:00	0,217456	-0,426883	9,6905	9,87925
05.01.2020 20:00	0,0300472	-0,0368658	9,79465	9,9834
06.01.2020 10:00	0,120984	-0,293272	10,725	10,97425
06.01.2020 13:30	0,0381175	-0,178254	11,12275	11,372
06.01.2020 14:00	0,0353446	-0,17633	11,14045	11,3897
06.01.2020 14:30	0,0317739	-0,165228	11,1563	11,40555
06.01.2020 15:00	0,0753808	-0,234169	11,194	11,44325
06.01.2020 18:30	0,191918	-0,399717	11,5767	11,82595
06.01.2020 19:00	0,145551	-0,309489	11,64945	11,8987
06.01.2020 18:30	0,191918	-0,399717	11,5767	11,9219
06.01.2020 19:00	0,145551	-0,309489	11,64945	11,9947
06.01.2020 19:30	0,229093	-0,429647	11,764	12,10925
06.01.2020 21:30	0,0444433	-0,0588744	12,0931	12,43835

07.01.2020 2:00	0,193594	-0,392242	12,71	13,0552
07.01.2020 2:30	0,0519491	-0,0622846	12,736	13,0812
07.01.2020 8:00	0,105421	-0,264374	13,3357	13,7336
07.01.2020 14:00	0,0436145	-0,185799	13,88755	14,2855
07.01.2020 14:30	0,0599094	-0,216504	13,9175	14,31545
07.01.2020 15:00	0,0618371	-0,212627	13,94845	14,34635
07.01.2020 15:30	0,0502361	-0,190477	13,97355	14,3715
07.01.2020 16:00	0,0516891	-0,191506	13,9994	14,3973
07.01.2020 16:30	0,128707	-0,334874	14,06375	14,46165
07.01.2020 17:30	0,138383	-0,326101	14,20645	14,60435
08.01.2020 5:00	0,0993554	-0,280386	14,53385	14,98145
08.01.2020 13:30	-0,340787	2,53762	15,1046	15,5522
08.01.2020 14:00	0,0846612	-0,27069	15,14695	15,59455
08.01.2020 19:30	-1,32659	10,1459	14,96095	15,40855
09.01.2020 10:00	0,12083	-0,327099	15,2813	15,7893
09.01.2020 18:30	0,218135	-0,433672	16,27455	16,78255
09.01.2020 19:00	0,0152631	-0,0164213	16,28215	16,7902
11.01.2020 10:30	0,0389938	-0,178565	17,6194	18,1469
11.01.2020 11:30	0,0348736	-0,171077	17,65425	18,18175
11.01.2020 12:00	0,0264168	-0,161834	17,66745	18,19495
11.01.2020 12:30	0,0468329	-0,191074	17,69085	18,21835
11.01.2020 13:30	0,0385993	-0,182096	17,7327	18,2602
11.01.2020 14:00	0,037245	-0,183178	17,75135	18,27885
11.01.2020 14:30	0,0339431	-0,17722	17,7683	18,2958
11.01.2020 15:00	0,0279098	-0,165141	17,78225	18,30975
11.01.2020 15:30	0,0573515	-0,206358	17,81095	18,33845
11.01.2020 16:00	0,0447446	-0,184481	17,8333	18,3608
11.01.2020 16:30	0,0479438	-0,191312	17,8573	18,3848
11.01.2020 17:00	0,0446794	-0,186533	17,8796	18,4071
11.01.2020 17:30	0,0406597	-0,173024	17,89995	18,42745
11.01.2020 18:00	0,0469582	-0,187837	17,9234	18,45095
11.01.2020 18:30	0,0445314	-0,180201	17,9457	18,4732
11.01.2020 19:00	0,251153	-0,569401	18,07125	18,59875
11.01.2020 19:30	0,185439	-0,34497	18,164	18,6915
12.01.2020 11:30	0,048607	-0,195558	19,08805	19,63985
12.01.2020 12:30	0,0470587	-0,186624	19,1417	19,6935
12.01.2020 13:00	0,0553106	-0,203716	19,16935	19,72115
12.01.2020 15:30	0,0361783	-0,179938	19,2926	19,8444
12.01.2020 16:00	0,0438477	-0,189093	19,3145	19,8663
12.01.2020 16:30	0,0359948	-0,179454	19,3325	19,8843
12.01.2020 17:00	0,0431766	-0,188635	19,3541	19,9059
12.01.2020 17:30	0,0415966	-0,185633	19,3749	19,9267
12.01.2020 18:00	0,0331389	-0,0340005	19,39145	19,94325
12.01.2020 18:30	0,0439671	-0,180545	19,41345	19,96525
12.01.2020 19:00	0,0343185	-0,172671	19,4306	19,9824
12.01.2020 20:00	0,196741	-0,394482	19,5482	20,1

12.01.2020 21:00	-0,830159	1,99214	19,2381	19,7899
13.01.2020 17:00	0,0248628	-0,159217	20,2998	20,864
13.01.2020 18:00	0,0327079	-0,169199	20,33205	20,8963
13.01.2020 18:30	0,0377093	-0,173166	20,35095	20,91515
14.01.2020 1:30	-1,17687	0,279708	20,245	20,80925
14.01.2020 2:00	0,0793722	-0,235046	20,2847	20,84895
14.01.2020 18:30	0,233331	-0,46927	20,88885	21,4531
15.01.2020 19:30	0,105294	-0,260204	21,88255	22,4468
15.01.2020 20:00	0,0679414	-0,211687	21,91655	22,48075
24.01.2020 20:00	0,00611445	-0,463701	26,29945	26,8637
28.01.2020 18:30	0,159916	-0,355294	29,83155	30,3958
28.01.2020 19:00	0,103158	-0,259024	29,88315	30,44735
29.01.2020 16:00	0,000419887	-0,000398925	30,7618	31,32625
29.01.2020 17:30	0,0449994	-0,179274	30,82965	31,3941
29.01.2020 18:00	0,0412328	-0,178166	30,85025	31,4147
30.01.2020 0:30	0,0577779	-0,389908	31,1845	31,74895
30.01.2020 1:00	0,0544677	-0,438523	31,21175	31,7762

Описание применения разработанных методов оптимизации нормальных электрических режимов для оперативного и автоматического управления приведено в следующей главе.

3.9 Выводы по главе 3

По результатам исследований алгоритмов оптимизации, приведенных в главе 3, можно сделать следующие выводы.

1. В работе показана невыпуклость целевой функции статической оптимизации и предложены методы ее решения. Предложенный алгоритм LIPOP совместно с квазиньютоновским методом оптимизации LBFGBSВ может использоваться в цикле динамической оптимизации электрических режимов.
2. Сформулирована модель, которая может применяться для оптимизации электрических режимов с учетом стохастических элементов. Предложено использование интервальной арифметики для быстрой оценки распределения вероятности вектора состояния при решении задачи расчета установившегося режима в вероятностной постановке.
3. Предложен универсальный алгоритм стохастической оптимизации динамического процесса во времени с учетом зависящей от времени стоимости воздействий.

4. Предложенный алгоритм динамической оптимизации опробован на примере реальной энергосистемы и показал свою эффективность. Результаты динамической оптимизации близки к теоретическому минимуму, полученному по результатам статической оптимизации.

ГЛАВА 4. ПРОГРАММНАЯ РЕАЛИЗАЦИЯ

В главе представлена программная платформа, на базе которой были реализованы разработанные модели и алгоритмы. Далее представлено программное обеспечение системы интеллектуального управления напряжением и реактивной мощностью, наиболее полно включающей реализацию разработанных моделей.

4.1 Области применения

Представленные в работе модели реализованы в промышленном программном обеспечении для моделирования режимов электроэнергетических систем АНАРЭС [227].

Реализованы две подзадачи в виде отдельных программных модулей:

- Программа динамической оптимизации электрических режимов ЭЭС для ПВК АНАРЭС
- Система автоматического управления напряжением и реактивной мощностью в энергосистеме.

Программа (блок) динамической оптимизации электрических режимов ЭЭС разработан в составе комплекса АНАРЭС и в настоящее время (в 2020-2021 гг.) внедряется в Иркутской энергосистеме. Работа блока динамической оптимизации будет осуществляться в автоматическом режиме на основе ретроспективных данных оценивания состояния. Рассчитываемые для каждого момента управляющие воздействия доступны в виде рекомендаций оперативному персоналу. Таким образом, программное обеспечение динамической оптимизации электрических режимов ЭЭС выступает в качестве советчика диспетчеру.

Система автоматического интеллектуального управления напряжением и реактивной мощностью (см. П. 4.3) включает весь состав предлагаемых методик управления электрическим режимами, включая: оценивание состояния, прогнозирование режимов, динамическая оптимизация. Система разработана на программной платформе АНАРЭС в виде прототипа для дальнейшего внедрения в Магаданской энергосистеме. Работы по созданию прототипа уже завершены. Акт о внедрении подсистемы оптимального управления напряжением и реактивной мощностью энергосистемы/энергорайона приведен в приложении 4. Автором выполнен весь объем работ по разработке данных программных модулей в составе ПВК АНАРЭС.

4.2 Программная платформа

Программная реализация описанных модулей выполнена на платформе ПВК АНАРЭС [227]. Краткое описание ПВК АНАРЭС и его пользовательского интерфейса приведено в Приложении 3.

4.2.1 Архитектура взаимодействия программных модулей

Организация данных внутри комплекса АНАРЭС выполнена в виде объектной модели, которая включает в себя:

- объектную модель оборудования, разработанную по аналогии с CIM-моделью;
- модель узлы/ветви, формируемую топологическим процессором;
- объектную модель расчетных задач.

Для обеспечения взаимодействия в рамках программного комплекса разработана быстродействующая библиотека на языке C++.

Хранение данных в ПВК АНАРЭС организовано с использованием двух технологий: 1) файловая база данных; 2) база данных SQL.

Файловая база используется для локального хранения режимов. Режимы условно разделяются на расчетные схемы, каждая из которых может содержать множество режимов. Расчетная схема представляет подпапку в библиотеке режимов.

SQL база данных (anaresdb), разработанная на основе PostgreSQL, используется для эффективного хранения больших объемов данных, привязанных ко времени:

- срезы телеметрии;
- архивные режимы;
- оцененные режимы;
- прогнозные режимы.

Также механизм хранения в anaresdb позволяет хранить структурированные наборы оперативных корректировок параметров режимов.

Кроме взаимодействия внутри комплекса АНАРЭС, возможно взаимодействие расчетной подсистемы АНАРЭС с внешними системами. В качестве внешней системы может выступать SCADA или система автоматического, или автоматизированного управления.

Цели взаимодействия SCADA и АНАРЭС:

- Передача имеющихся в SCADA и смежных системах данных, которые могут быть использованы для выполнения расчетов электрических режимов в АНАРЭС.
- Передача коммутационного состояния сети.
- Передача команд на выполнение фоновых расчетов в ПВК АНАРЭС (оценивание состояния и установившийся режим).
- Отображение результатов фоновых расчетов.

- Запуск приложений ПВК АНАРЭС для выполнения расчетов в интерфейсе АНАРЭС (все задачи ПВК АНАРЭС).

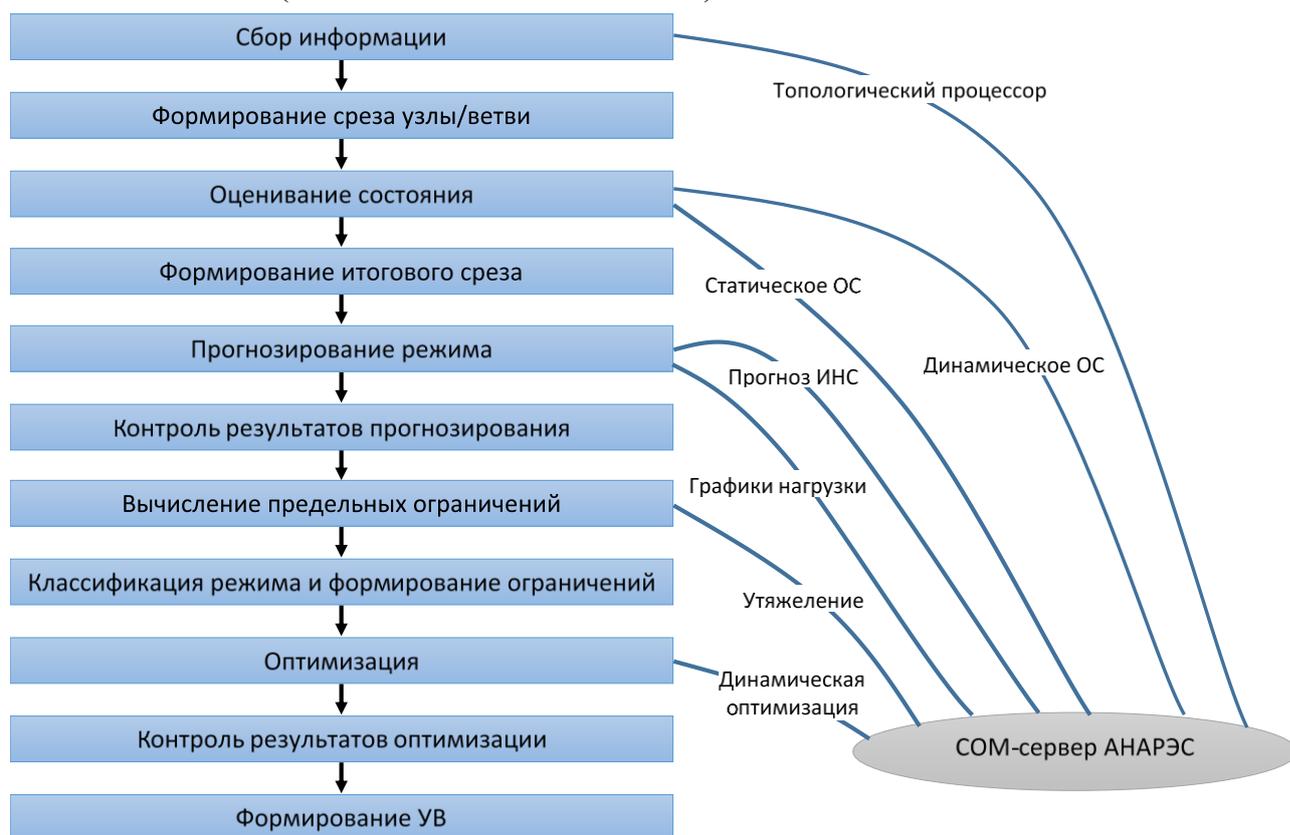


Рис. 4.1 – Встраиваемая версия расчетной подсистемы.

Для операционных систем семейства Windows встраиваемая версия реализована в виде COM-сервера (Рис. 4.1). Все данные передаются в универсальном JSON формате. Результаты также передаются в подсистему оптимального управления напряжением и реактивной мощностью в формате JSON.

Для Linux возможна реализация встраиваемой версии подсистемы оптимального управления в виде RESTful web-сервера, взаимодействующего с целевой системой в формате JSON.

4.2.2 Программная платформа для реализации ИНС

В качестве программной платформы для реализации моделей, основанных на искусственных нейронных сетях, используется библиотека TensorFlow, API которой реализован на языке Python. Большим преимуществом использования библиотеки TensorFlow является поддержка параллельных вычислений с использованием GPU и библиотеки CUDA без необходимости модификации пользовательского кода, реализующего ИНС.

Важной особенностью программной реализации нейро-аналитических сетей (НАС), представленных в разделе 2.6, является тесная интеграция алгоритмов, реализующих кластеры ИНС, с вычислительными алгоритмами, реализованными на C++.

Для интеграции Python с кодом на C++ используется библиотека Boost.Python. Основной средой выполнения модели НАС является среда АНАРЭС, разработанная на C++. Код Python выполняется под управлением кода C++. При этом реализован универсальный механизм подготовки объектов numpy из рабочих массивов модуля расчета установившегося режима и загрузки результатов вычислений ИНС на каждой итерации обучения и прогнозирования. Обобщенная схема взаимодействия представлена на Рис. 4.2.

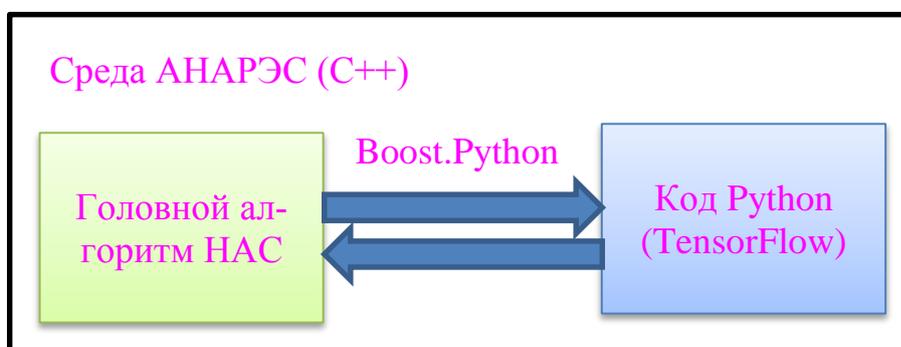


Рис. 4.2 – Встраиваемая версия расчетной подсистемы.

4.3 Система интеллектуального управления напряжением и реактивной мощностью в энергосистеме

4.3.1 Общее описание системы ИУНРМ

Все разработанные модели применены в разработанном прототипе системы интеллектуального управления напряжением и реактивной мощностью (ИУНРМ), выполненном для Магаданской энергосистемы (Рис. 4.3). Особенностью предлагаемого решения является возможность учета возобновляемых источников ЭЭ и стохастической нагрузки.

Особенности Магаданской ЭЭС – это сосредоточенная генерация, представленная несколькими крупными станциями, такими, как Колымская и Усть-Среднеканская ГЭС, а также нагрузка, расположенная за достаточно протяженными электрическими сетями. Такая конфигурация ЭЭС создает сложности с оптимальным регулированием напряжения в сети. Если в нормальной схеме, в зависимости от времени года и общей нагрузки, можно установить некоторый уровень напряжения на шинах ГЭС, который будет оптимален для всей ЭЭС, то в ремонтных режимах будут иметь место ситуации, при которых в одной части ЭЭС напряжение будет

ниже номинального, а в другой части напряжение будет близко к максимально допустимому. В таких условиях централизованное регулирование напряжения в Магаданской ЭЭС только за счет изменения генерации реактивной мощности ГЭС оказывается неэффективным.

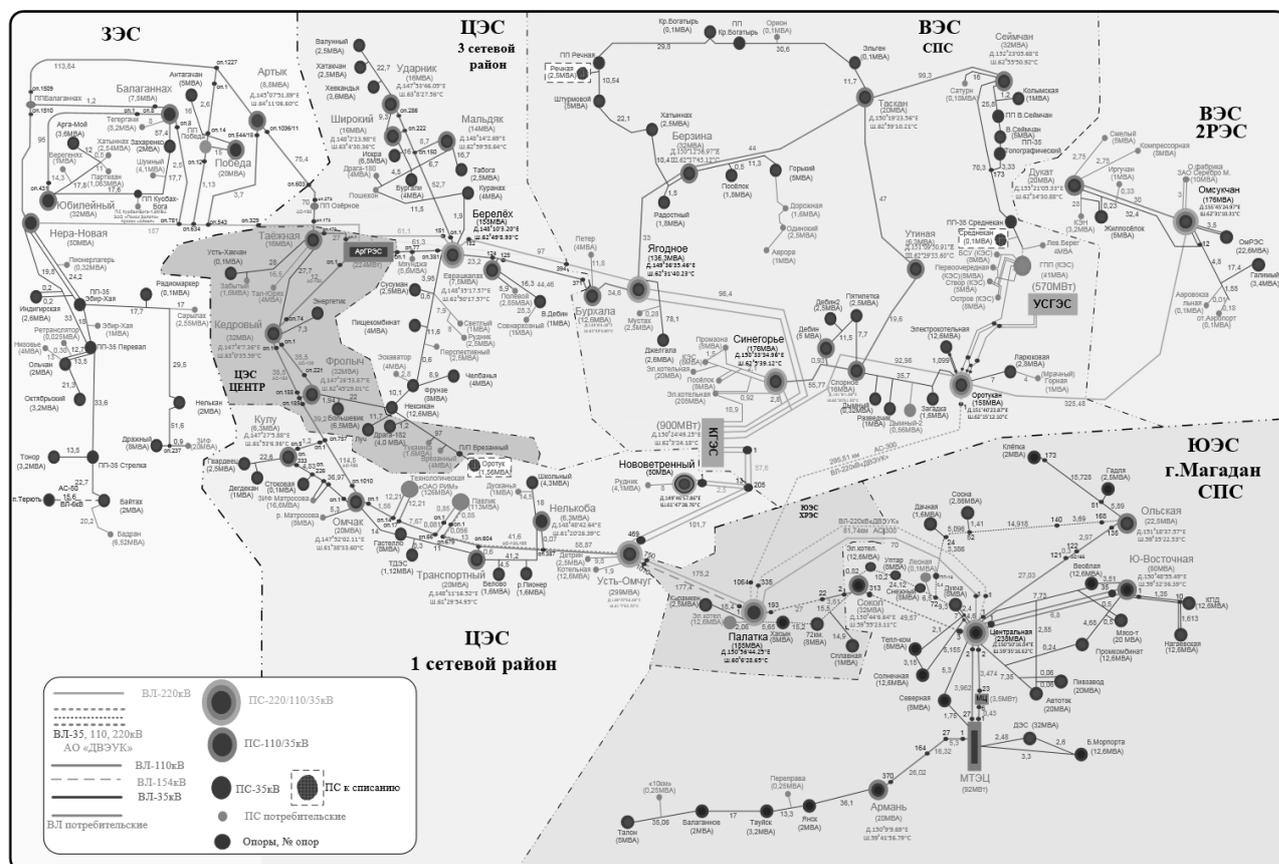


Рис. 4.3 – Схема Магаданской ЭЭС.

Фактически единственным эффективным способом регулирования напряжения в Магаданской ЭЭС является использование существующих и установка дополнительных источников реактивной мощности (ИРМ), которые, будучи выполненными в управляемом исполнении, уже являются элементами активно-адаптивной электрической сети.

Учитывая, что часто проблемы с напряжениями возникают во время аварий, которые являются случайными и непрогнозируемыми событиями, то для исключения ситуаций нарушения статической устойчивости необходимо обеспечить автоматическое управление ИРМ.

В Магаданской ЭЭС на текущий момент уже используются комплекты БСК+УШР. В будущем возможна дополнительная установка устройств регулирования реактивной мощности. В общем виде, рассматривая задачу управления напряжением, можно выделить два способа размещения и управления ИРМ:

1-й способ – избыточный, когда на важных узловых подстанциях устанавливаются ИРМ с большим резервом управления в части генерации и потребления реактивной мощности. Имея резервы реактивной мощности, можно в данной точке сети в любом режиме обеспечить фиксированный уровень напряжения. Собственно, алгоритм управления в данном случае является локальным, т.е. по локальному замеру напряжения на ПС осуществляется выбор состава включенных в работу элементов ИРМ (конденсаторов, управляемых и неуправляемых реакторов). Недостатком данного способа является необходимость установки избыточного состава элементов ИРМ на нескольких узловых ПС. Учитывая, что стоимость ИРМ, это не только стоимость конденсаторов и реакторов, но и стоимость ячеек (220, 110, 35, 10 кВ), то данный недостаток является существенным.

2-й способ – координированный, когда на важных узловых подстанциях устанавливаются ИРМ с минимальным резервом управления в части генерации и потребления реактивной мощности. Поддержание напряжения в оптимальном диапазоне осуществляется за счет координированного управления ИРМ на разных объектах, в сочетании с координированным управлением напряжением на шинах электростанций. По сравнению с 1-м способом, здесь потребуется более сложная система распределенного управления, требующая каналов связи, однако при этом значительно снижаются требования к объему первичного оборудования ИРМ, что особенно существенно с учетом того, что резервы мощности ИРМ определяются с учетом возможных ремонтов элементов ИРМ.

Наиболее перспективным и одновременно более целесообразным с экономической точки зрения является 2-й способ, который и был реализован при выполнении разработки системы интеллектуального управления напряжением и реактивной мощностью Магаданской ЭЭС.

4.3.2 Архитектура системы

Для обеспечения надежности и безошибочности управления, комплекс автоматического управления напряжением и реактивной мощностью разделен на несколько функциональных систем. Структура комплекса представлена на Рис. 4.4.

На нижнем уровне комплекса располагаются локальные контроллеры регулирующих устройств и централизованная координирующая система режимной автоматики. На верхнем уровне – система оптимального управления напряжением.

Функции централизованной координирующей системы режимной автоматики:

- Взаимодействие с низовыми устройствами управления и их контроль;

- Передача информации о состоянии локальных контроллеров в систему оптимального управления по стандартному протоколу (МЭК 60870-5-104 или МЭК 61850).
- Обработка контрольного задания из системы оптимального управления.
- Передача управляющих действий локальным контролерам. Преобразование управляющих воздействий в вид, необходимый для конкретного типа регулятора.
- Контроль технологических ограничений и согласованности ограничений.
- Регистрация и архивирование информации, включая входящие команды из подсистемы оптимального управления.



Рис. 4.4 – Обобщенная структура комплекса управления напряжением.

Координирующая система режимной автоматики – это внешняя система (разработанная компанией «Энергия-Т»), с которой взаимодействует подсистема оптимального управления напряжением и реактивной мощностью, разработанная автором.

Подсистема оптимального управления напряжением и реактивной мощностью энергосистемы (энергорайона) предназначена для расчета управляющих воздействий и уставок локальных регуляторов режимной автоматики для оптимального управления напряжением и реактивной мощностью энергосистемы (энергорайона)

в реальном времени на основе данных телеметрии и циклического решения оптимизационных задач с учетом заданных ограничений и критериев оптимального (допустимого) управления.

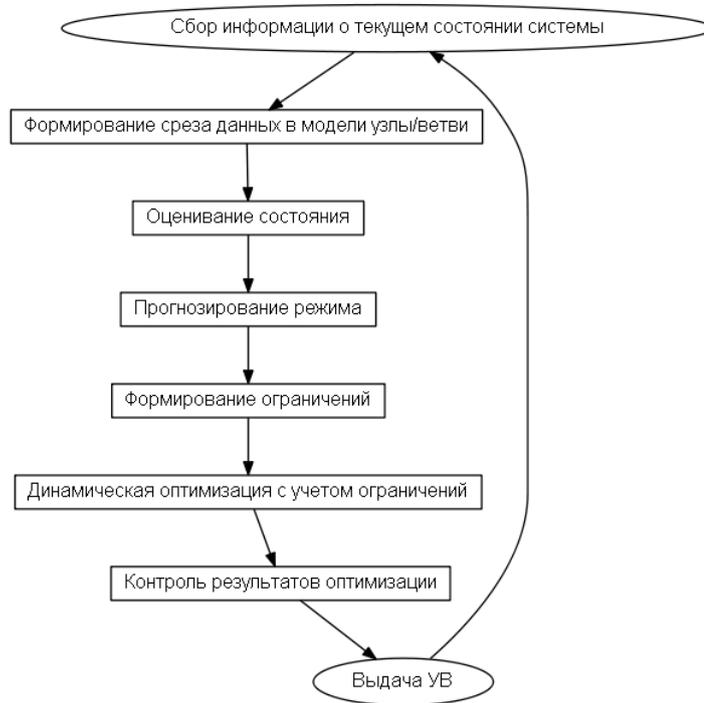


Рис. 4.5 – Укрупненный алгоритм работы подсистемы оптимального управления напряжением и реактивной мощностью энергосистемы (энергорайона).

В подсистеме оптимального управления напряжением и реактивной мощностью циклически выполняются следующие задачи (Рис. 4.5):

- Сбор информации о текущем состоянии системы.
- Формирование и актуализация модели узлы/ветви.
- Оценивание состояния.
- Прогнозирование режима.
- Формирование ограничений для оптимизации.
- Динамическая оптимизация с учетом ограничений.
- Анализ результатов оптимизации.
- Формирование управляющих воздействий и их передача в координирующую систему.

Выход из строя вычислительно-емких математических алгоритмов подсистемы оптимального управления не приводит к выходу из строя всей системы, а переводит систему на работу по локальным алгоритмам управления, обеспечивающим менее оптимальное, но допустимое управление. Кроме того, сама система оп-

тимального управления предусматривает функциональное резервирование каждого из вычислительных алгоритмов. Прогнозирование с использованием алгоритмов машинного обучения резервируются более грубыми алгоритмами прогнозирования на основе графиков нагрузок. Динамическая оптимизация резервируется статической.

Предлагаемый подход к построению комплекса автоматического управления напряжением позволяет совместить современные методы машинного обучения с классическими вычислительными методами, что обеспечивает высокую надежность управления.

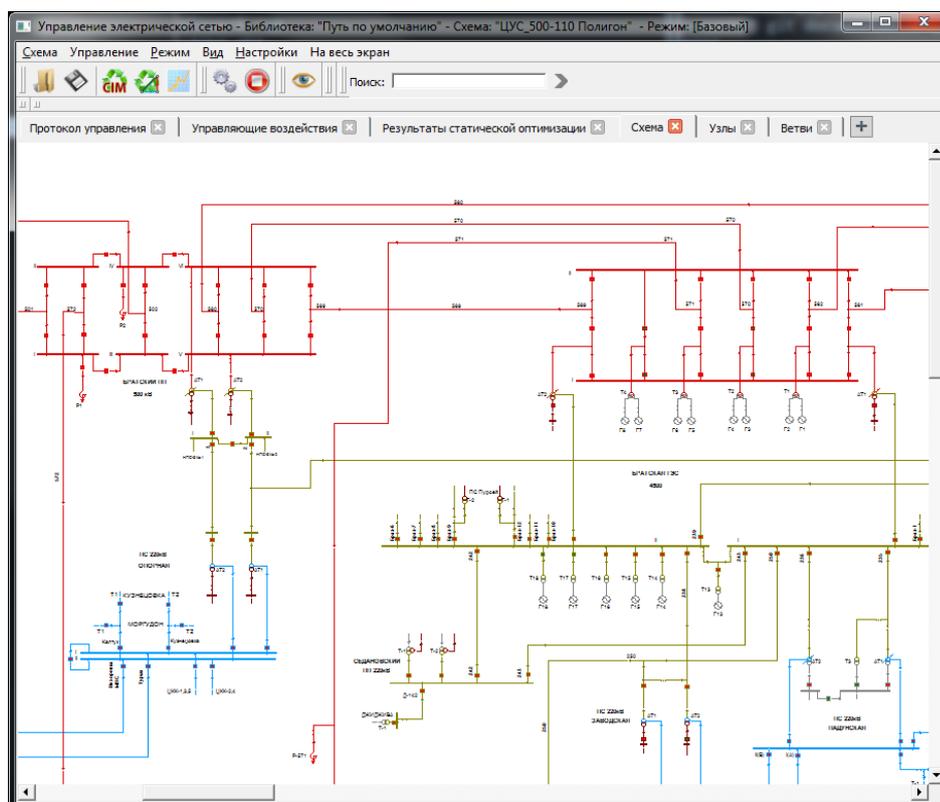


Рис. 4.6 – Главное окно приложения «Управление электрической сетью».

Подсистема оптимального управления (Рис. 4.6) включает в свой состав следующие приложения:

- **Управление электрической сетью (GridControl)** – основное приложение в рамках которого выполняются все управляющие алгоритмы.
- **Установившийся режим (UR)** – расчет и оптимизация установившихся режимов. В данном приложении выполняется начальная подготовка моделей электрических сетей для использования в подсистеме оптимального управления.

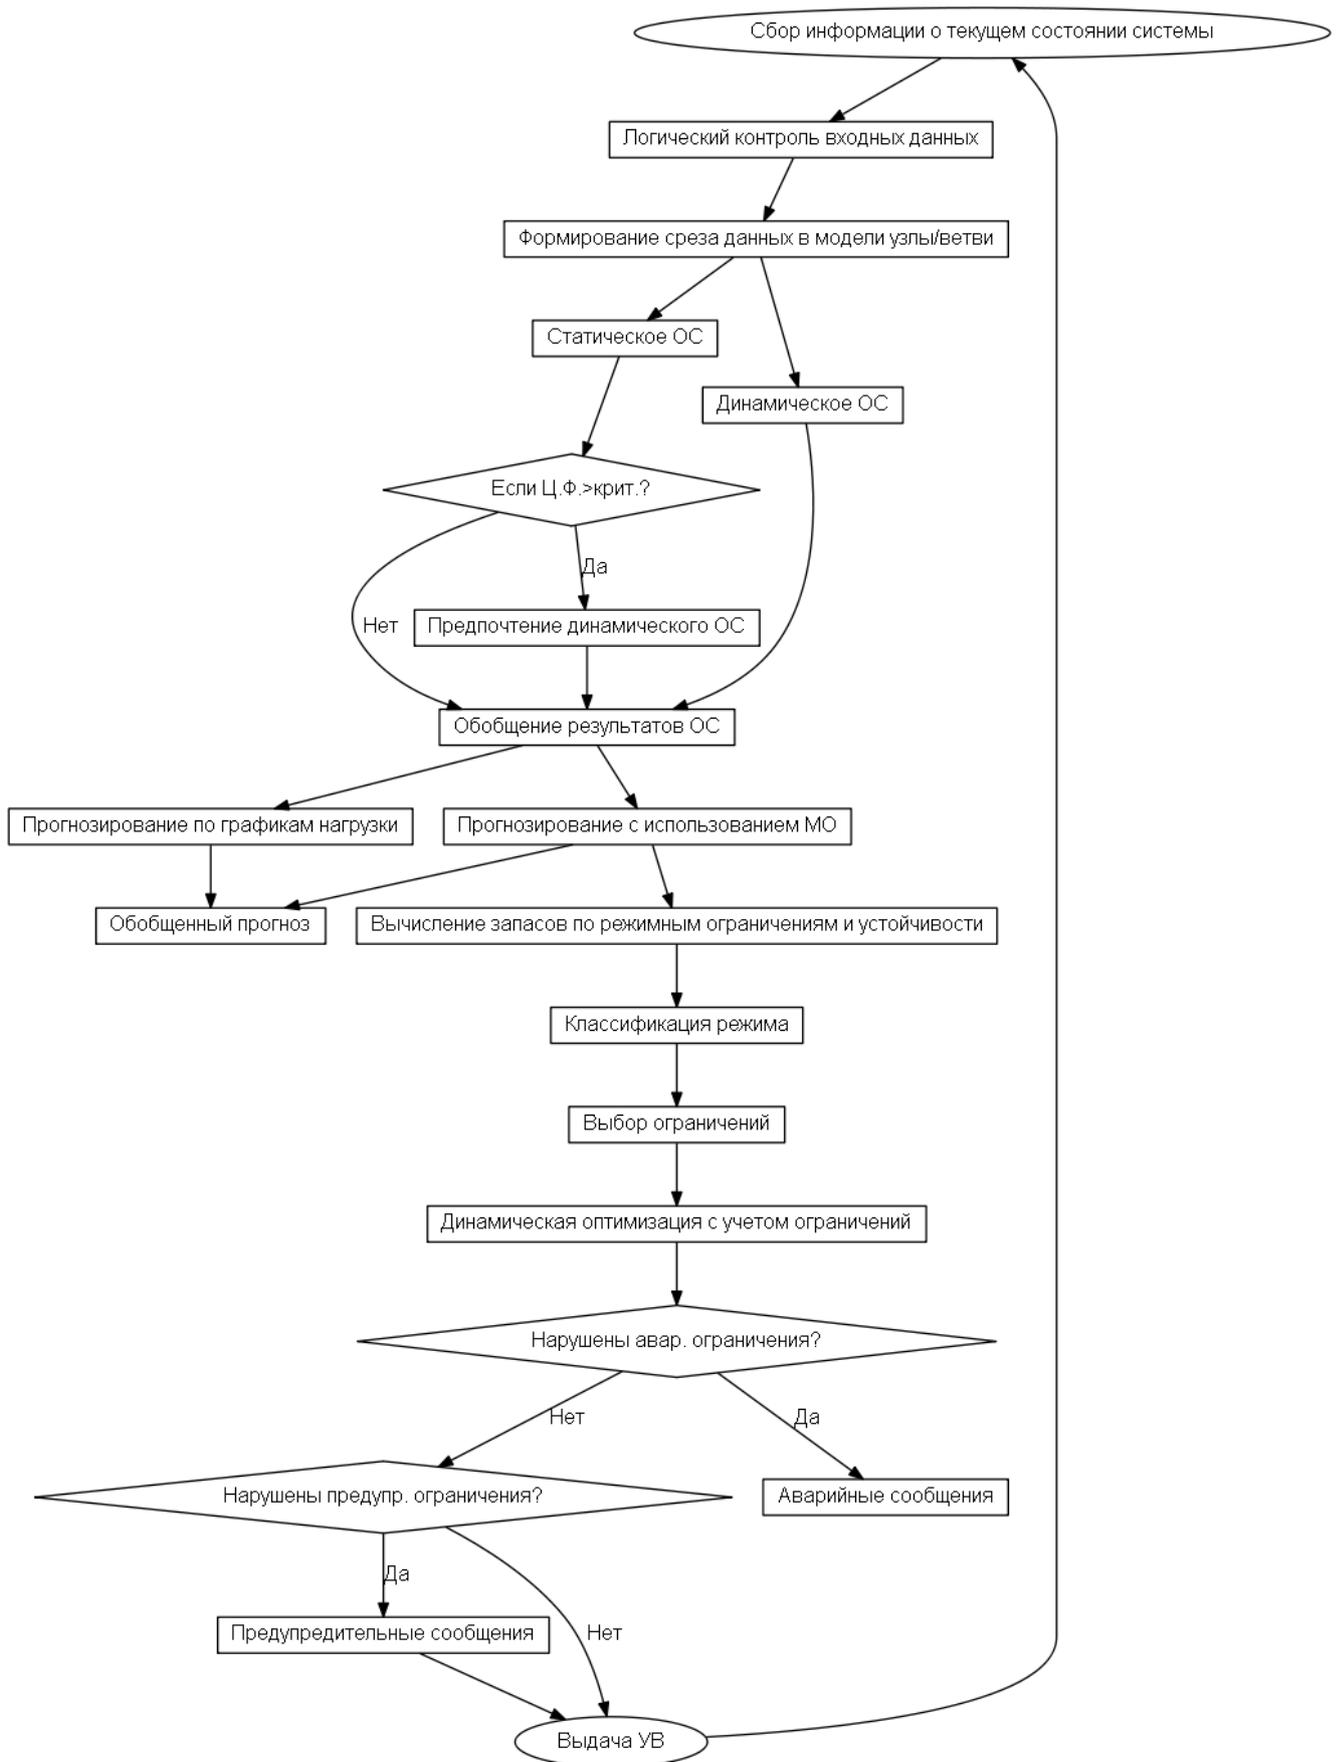


Рис. 4.7 – Один цикл работы алгоритма управления.

- **Интегратор потерь (StatLoss)**. Сервисное приложения для формирования результатов расчета потерь в разрезе элементов оборудования, уровней напряжения за период, задаваемый пользователем.

4.3.3 Управление электрической сетью

Приложение «Управление электрической сетью» (GridControl) обеспечивает выполнение циклического алгоритма интеллектуального управления напряжением и пользовательский интерфейс для настройки и управления алгоритмами интеллектуального управления.

Обобщенная блок-схема алгоритма оптимального управления представлена Рис. 4.7. Пользовательский интерфейс приложения представлен на скриншоте (Рис. 4.6). Интерфейс выполнен на базе интерфейса ПВК АНАРЭС и содержит все его основные элементы.

4.3.4 Взаимодействие с внешними подсистемами

Подсистема оптимального управления взаимодействует с внешними системами через SQL базу данных anaesdb, располагаемую на сервере БД. В качестве сервера БД применяется PostgreSQL.

Получение среза телеизмерений и состояния коммутационных аппаратов осуществляется через SQL-запрос к архивной базе данных.

Архивные срезы данных формируются сервером сбора и передачи информации АНАРЭС-ССПИ [236]. Система сбора и передачи информации АНАРЭС-ССПИ предназначена для:

- Сбора текущей телеинформации по протоколу МЭК 60870-5-104;
- Формирования и сохранения в БД срезов телеинформации с заданной периодичностью;
- Выдачи наборов управляющих воздействий;
- Ведения архивов принимаемой и выдаваемой информации.

АНАРЭС-ССПИ реализована в виде демона Linux. Требования к операционной системе и СУБД:

- RHEL совместимая версия Linux. Рекомендуется CentOS 8.
- PostgreSQL 10

4.3.5 Формирование среза в модели узлы/ветви

После получения среза в ПОУ ИУНРМ выполняется оценивание состояния текущего режима. Для того, чтобы актуализировать исходные данные для оценива-

ния состояния, необходимо сопоставить ТИ/ТС с расчетной моделью АНАРЭС. Такое сопоставление обеспечивается за счет «привязки» ТИ/ТС к расчетной модели (схеме).

Привязка осуществляется с графической схемы, представленной в АНАРЭС, и хранится соответственно в графической схеме. Такой подход позволяет не увеличивать размер расчетной модели до коммутационных схем. Таким образом, в результате «привязки» связываются элемент графической схемы с одним ТС и несколькими (по числу типов) ТИ. Например, ТС состояния выключателя, переток P через выключатель, переток Q через выключатель. В качестве ТС и ТИ может выступать формула, задаваемая в АНАРЭС. Привязка осуществляется по уникальному идентификатору ТС/ТИ.

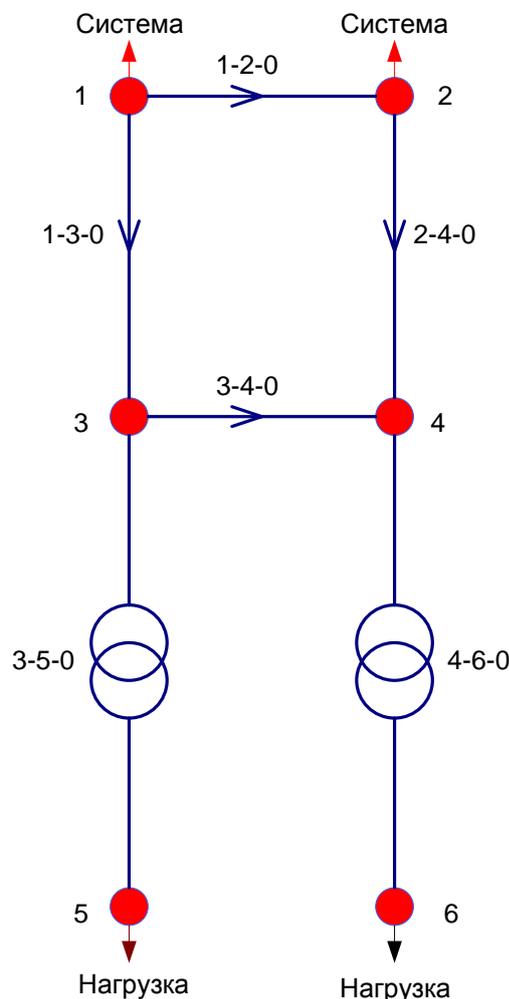


Рис. 4.8 – Пример модели электрической сети.

Преобразование измерений и телесигналов до уровня модели узлы/ветви осуществляется топологическим процессором АНАРЭС. Моделью энергосистемы узлы/ветви является схема замещения электроэнергетической системы или сети, которая эквивалентна данной электрической схеме и адекватно отражает процессы,

происходящие в ней. В схеме замещения реальные элементы сети (физические устройства) заменяются идеализированными элементами (активными сопротивлениями, емкостями, индуктивностями, идеальными трансформаторами, задающими токами и мощностями).

Схему замещения можно представить в виде графа, состоящего из узлов и соединяющих их ветвей (Рис. 4.8). На рисунке узлы обозначены красным цветом, а ветви – синим. Под узлом понимается набор соединенных элементов одного класса напряжения, имеющих сопротивление равное нулю, либо близкое к нулю, которым для данного вида расчета можно пренебречь.

Для автоматического формирования упрощенной модели из полной модели используется задача автоматического формирования расчетной модели (топологический процессор). Следует отметить, что упрощение модели выполняется только с точки зрения представления информации. Точность вычислений при этом несколько не ухудшается. Кроме того, упрощенная модель узлы/ветви не содержит ветвей с сопротивлением близким к нулю, тем самым улучшается сходимость процесса расчета установившегося режима.

4.3.6 Просмотр результатов управления

В программном обеспечении интеллектуального управления напряжением и реактивной мощностью предусмотрен пользовательский интерфейс для наглядного представления результатов управления.

В протокол управления (Рис. 4.9) выводятся сообщения о выполнении основных этапов циклического алгоритма управления и сообщения обо всех программных ошибках, которые могут происходить в процессе управления.

На каждом цикле процесса управления подготавливается таблица управляющих воздействий с указанием времени их применения. Управляющие воздействия вычисляются для всего прогнозного горизонта времени. При этом, на каждой итерации процесса управления пересчитывается вся таблица управляющих воздействий, начиная от текущего оцененного режима.

Просмотреть список управляющих воздействий, вычисленный в процессе динамической оптимизации, можно на вкладке «Управляющие воздействия» (Рис. 4.10). Именно эти управляющие воздействия передаются в централизованную координирующую управляющую систему режимной автоматики в виде тэгов с временем, соответствующим требуемому времени применения данного управляющего воздействия.

№	Содержимое
1	Подключение к БД успешно
2	Чтение текущего среза - успешно: 18.04.2020 20:40:38
3	Оценивание состояния: Сб апр 18 20:40:38 2020 ЦФ=2976
4	Прогноз сохранен
5	Выбранны ограничения: нормального режима
6	Начальная целевая функция: 25752.5
7	Динамическая оптимизация за период завершена: ЦФ до=28933.9 ЦФ после=28933.6
8	Длительность цикла управления: 32 сек.
9	Оценивание состояния: Сб апр 18 20:41:10 2020 ЦФ=3506
10	Прогноз сохранен
11	Выбранны ограничения: нормального режима
12	Начальная целевая функция: 25752.5
13	Динамическая оптимизация за период завершена: ЦФ до=28933.9 ЦФ после=28933.6
14	Длительность цикла управления: 32 сек.
15	Оценивание состояния: Сб апр 18 20:41:43 2020 ЦФ=3506
16	Прогноз сохранен
17	Выбранны ограничения: нормального режима
18	Начальная целевая функция: 25752.5
19	Динамическая оптимизация за период завершена: ЦФ до=2146.04 ЦФ после=2146.06
20	Длительность цикла управления: 11 сек.
21	Управляющий процесс остановлен

Рис. 4.9 – Протокол управления.

Таблица управляющих воздействий содержит следующие поля:

- **Дата/время** – дата и время, в которое необходимо применить данное воздействие;
- **Снижение потерь** – Снижение потерь в данном режиме.
- **Снижение отклонения напряжения** – Снижение отклонения напряжения в данном режиме.
- **Суммарное снижение потерь (дин. опт.)** – Снижение потерь нарастающим итогом за выбранный период по результатам динамической оптимизации.
- **Суммарное снижение потерь** – Снижение потерь нарастающим итогом за выбранный период по результатам статической оптимизации.
- **Параметр** – Параметр модели, который соответствует управляющему воздействию.

- **Значение** – значение управляющего параметра, вычисленное в результате динамической оптимизации. Именно оно передается в качестве управляющего воздействия.

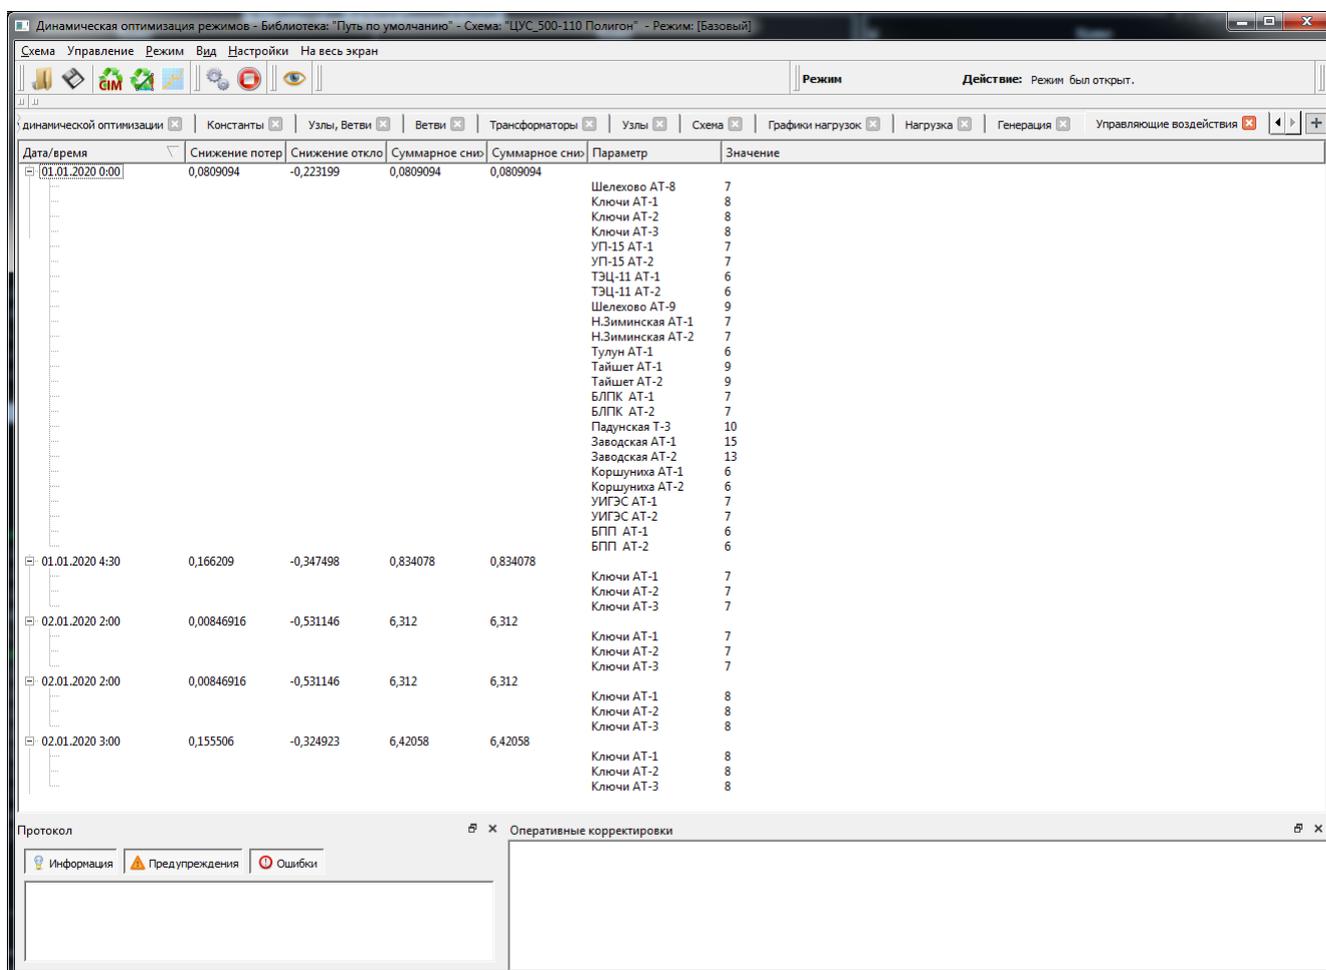


Рис. 4.10 – Текущие подготовленные управляющие воздействия.

График	Таблица	1.04.2019 00:00	01.04.2019 00:30	01.04.2019 01:00	01.04.2019 01:30	01.04.2019 02:00	01.04.2019 02:30	01.04.2019 03:00	01.04.2019 03:30	01.04.2019 04:00	01.04.2019 04:30
Рген	исх.прог.инс Братская ГЭС ГГ-5-6 (13)	219.626	217.355	213.404	223.175	452.829	389.658	390.208	438.706	437.818	384.986
Рген	исх. Братская ГЭС ГГ-5-6 (13)	219.626	217.561	213.130	221.715	406.707	388.909	390.087	433.133	437.073	389.644
Рген	исх.прог. Братская ГЭС ГГ-5-6 (13)	219.626	218.633	215.558	218.129	330.101	398.349	389.541	415.865	435.105	415.880

Рис. 4.11 – Отображение прогноза и архивных значений в таблице.

Для возможности анализа работы подсистемы оптимального управления напряжением и реактивной мощностью можно просматривать любые промежуточные результаты, в том числе:

- Прогноз фактического и спрогнозированного изменения выбранных параметров режима на графике (Рис. 4.12) и в таблицах (Рис. 4.11).

- Архивный режим, прогнозный режим или текущий оцененный режим на графической схеме и в таблицах.
- Архив выданных управляющих воздействий.

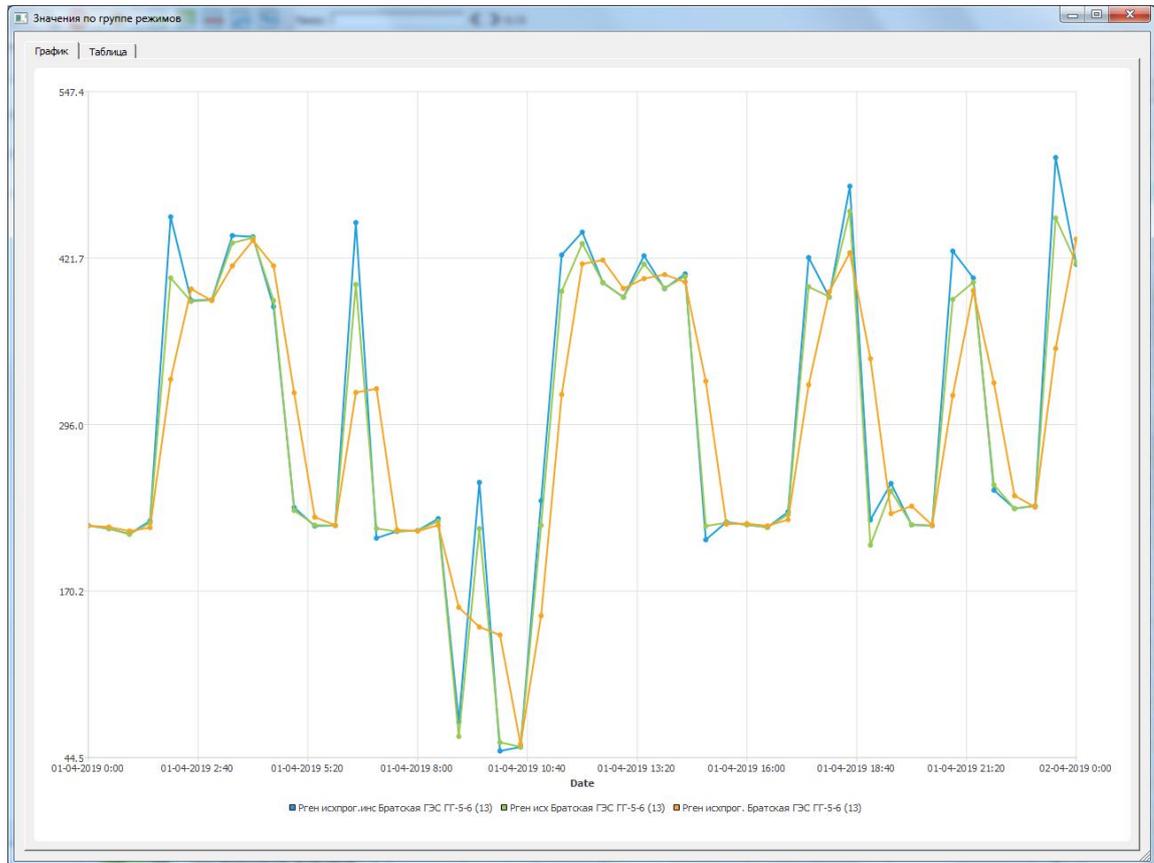


Рис. 4.12 – Отображение прогноза и архивных значений на графике.

4.3.7 Имитационная подсистема

Для имитации поведения энергосистемы с целью тестирования подсистемы оптимального управления (ПОУ ИУНРМ) и отладки модели энергосистемы разработана имитационная подсистема ПТК ИУНРМ. Имитационная подсистема ПТК ИУНРМ фактически является цифровым двойником энергосистемы.

Имитационная подсистема выступает в качестве источника данных по протоколу МЭК 60870-5-104, не отличаясь от реальных источников телеизмерений. Переключение источника данных осуществляется оператором в программном обеспечении управления напряжением и реактивной мощностью. Однако, фактическое переключение источника данных осуществляется в сервере сбора и передачи информации. Таким образом, имитационная подсистема полностью подменяет энергосистему, имитируя как поведение самой энергосистемы, так и координирующей подсистемы ПТК ИУНРМ вместе с устройствами управления ПТК. В состав имитационной подсистемы входит:

- Интеграционная платформа, обеспечивающая:

- Получение информации (ТИ, ТС) о текущем состоянии энергорайона.
 - Формирование срезов телеинформации в БД подсистемы оптимального управления.
 - Имитацию работы централизованной координирующей системы режимной автоматики.
 - Выполнение имитационных алгоритмов.
- Базовая расчетная платформа на основе ПВК АНАРЭС:
 - Система подготовки данных для расчета режимов;
 - Система отображения.

Приложения имитационной подсистемы ИУНРМ разработаны на программной платформе АНАРЭС (Рис. 4.13), которая используется для:

- подготовки исходных данных,
- отображения информации пользователю,
- формирования модели узлы/ветви топологическим процессором.

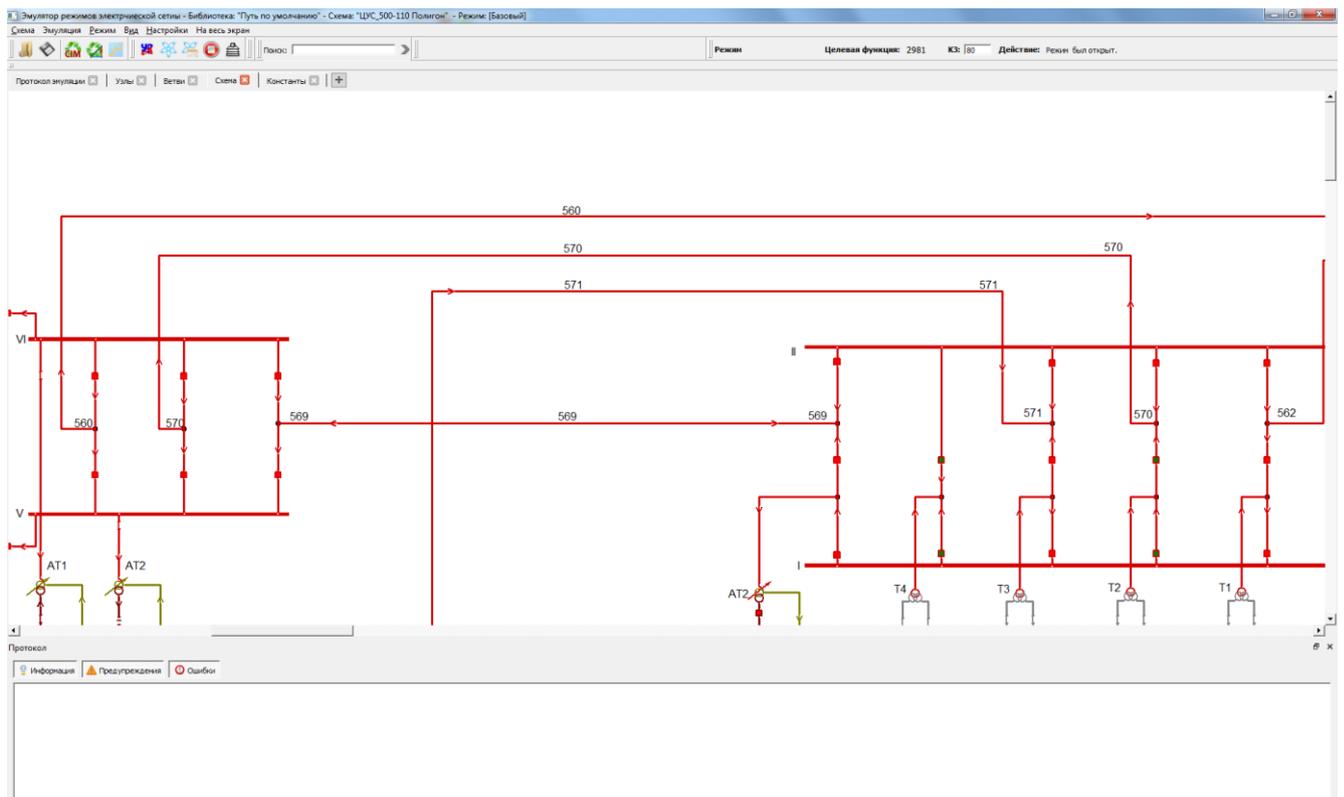


Рис. 4.13 – Главное окно приложения «Эмулятор режимов электрической сети».

Для обеспечения достоверного и надежного тестирования используются разные реализации математических моделей в имитационной подсистеме и подсистеме оптимального управления.

Алгоритм имитации основан на архивных данных об изменении нагрузки и на каждой итерации выполняет следующие действия:

- Получение архивного среза данных.
- Аппроксимация нагрузок для обеспечения их изменения в темпе процесса.
- Применение модели случайных блужданий для имитации изменчивости нагрузки.
- Чтение и наложение управляющих воздействий.
- Моделирование режима с учетом квазидинамического поведения системы.
- Формирование и запись выходного среза текущих измерений.

№	№ экв	Название	U ном	U оц	Pн исх	DPн	Qн исх	DQн	Pген исх	Qген исх	
108	108	Иркутская АТ-8 НН	10.50	10.26	0.00	0.1	0.00	0.1	0.00	-42.89	
109	109	Иркутская АТ-9 НН	10.50	10.79	0.00	0.1	0.00	0.1	0.00	-33.67	
110	110	Иркутская АТ-10 НН	x	10.50	0.00	0.1	0.00	0.1	0.00		
14	14	Братская ГЭС ГГ-7-8	x	15.00	0.00	0.1	0.00	0.1	0.00		
13	13	Братская ГЭС ГГ-5-6		15.00	15.24	0.00	0.1	0.1	187.31	-3.68	
12	12	Братская ГЭС ГГ-3-4	x	15.00	0.00	0.00	0.1	0.00	0.00	0.00	
11	11	Братская ГЭС ГГ-1-2		15.00	15.20	0.00	0.1	0.1	-8.99	-14.27	
6	6	Братская ГЭС АТ-2 НН		10.50	10.33	2.33	0.1	1.18	0.1	0.00	
5	5	Братская ГЭС АТ-1 НН		10.50	10.46	2.17	0.1	1.03	0.1	0.00	
63	63	Усть-Илимская ГЭС ГГ-5-6		15.00	15.18	0.00	0.1	0.00	0.1	190.77	-30.68

Рис. 4.14 – Задание дисперсий нагрузок.

Глубина архива входных архивных срезов может быть значительно больше длительности цикла имитационной подсистемы. Для обеспечения адекватности изменения нагрузок в темпе процесса эмуляции, значения мощности нагрузки для каждого момента времени аппроксимируются по значениям, полученным из архивных срезов. Таким образом, архивные срезы используются только для задания адекватного основного тренда изменения режима.

Для обеспечения имитации случайных изменений нагрузок режима применяется модель случайных блужданий в пределах заданной дисперсии. Дисперсия нагрузок задается для каждого узла модели (Рис. 4.14).

4.4 Выводы по главе 4

1. В главе описана архитектура разработанной автором промышленной системы автоматического интеллектуального управления напряжением и реактивной мощностью в энергосистеме. Описаны программные средства и платформы, примененные при разработке системы.
2. Разработан блок динамической оптимизации в составе ПВК АНАРЭС, позволяющий выполнять динамическую оптимизацию на основе прогнозных или архивных данных с учетом стохастического поведения ЭЭС.
Разработанное ПО оптимизации режимов внедряется в 2020 – 2021 гг. в виде советчика диспетчера, которое будет работать в автоматическом режиме в Иркутской сетевой компании. Свидетельство о регистрации программы для ЭВМ приведено в приложении 6.
3. Разработана подсистема оптимального управления напряжением и реактивной мощностью энергосистемы/энергорайона. Данная подсистема внедряется в рамках программно-технического комплекса интеллектуального управления напряжением и реактивной мощностью (ПТК ИУНРМ) Магаданской энергосистемы.
В настоящее время завершены работы по созданию прототипа. Акт о внедрении приведен в приложении 4.
4. 3. Программное обеспечение автоматического оптимального управления режимами совместно с цифровым двойником энергосистемы, разработанном на основе ПВК АНАРЭС внедрено в учебный процесс в Иркутском национальном исследовательском техническом университете. Акт о внедрении приведен в приложении 5.

ЗАКЛЮЧЕНИЕ

Диссертационная работа посвящена разработке методов прогнозирования и оптимизации нормальных электрических режимов электроэнергетических систем для задач оперативного и автоматического управления. Реализация данных методов позволяет применять их как для управления режимами с участием человека в виде советчика диспетчера, так и для полностью автоматического управления нормальными режимами энергосистем в составе режимной автоматики.

1. В работе показано, что для автоматического и автоматизированного управления нормальными электрическими режимами требуются адаптивные алгоритмы прогнозирования, использующие машинное обучение и алгоритмы динамической оптимизации.
2. Различные алгоритмы машинного обучения могут использоваться для решения локальных задач в энергетике, например, на уровне электроэнергетической установки или микро-сетей. Проанализировано применение различных методов машинного обучения для прогнозирования электрических режимов. В качестве наиболее подходящей из существующих архитектур глубокого обучения для прогнозирования режимов выбрана архитектура глубоких LSTM сетей. Однако, данная архитектура имеет ограничения при прогнозировании режимов реальной ЭЭС из-за большой вычислительной сложности при обучении.
3. Предложена новая модель ИНС – нейро-аналитическая сеть (НАС). В архитектуре НАС используется кластеризация и применяется байесовский вариант сети LSTM для каждого кластера. В качестве объединяющего слоя применяется аналитический слой, выполняющий одну итерацию расчета установившегося режима. Результатом работы алгоритма прогнозирования является набор прогнозных режимов на рассматриваемый горизонт прогнозирования, а также распределения вероятности для каждого прогнозного значения.
4. Для оптимального управления нормальными электрическими режимами в энергосистеме с наличием активной нагрузки предлагается комбинированный метод оптимизации, использующий модель машинного обучения для прогнозирования режимов электрической сети совместно с аналитическим методом динамической оптимизации.

5. Предложен метод динамической оптимизации режимов, работающая на основе получаемого с помощью нейро-аналитической сети прогноза, позволяющий учитывать вероятностные характеристики прогноза.
6. Предложен новый алгоритм стохастической оптимизации, который может использоваться для оптимального управления процессами, когда стоимость управляющего воздействия зависит от прошлого времени его применения.
7. Предлагаемые методы прогнозирования и динамической оптимизации нормальных электрических режимов ЭЭС реализованы в виде встраиваемого программного обеспечения и могут использоваться в системах автоматического и автоматизированного управления.
8. На базе предложенных методов и моделей разработана подсистема оптимального управления напряжением и реактивной мощностью энергосистемы/энергорайона. Данная подсистема внедряется в рамках программно-технического комплекса интеллектуального управления напряжением и реактивной мощностью (ПТК ИУНРМ) Магаданской энергосистемы, а также используется в учебном процессе в ИрННТУ.
9. Разработан блок динамической оптимизации в составе ПВК АНАРЭС, позволяющий выполнять динамическую оптимизацию на основе прогнозных или архивных данных с учетом стохастического поведения ЭЭС. Данное ПО внедряется в 2020 – 2021 гг. в Иркутской сетевой компании.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК**Список использованных источников**

1. Bamberger Y. et al. Vision and Strategy for Europe's Electricity Networks of the Future: European Technology Platform SmartGrids. 2006. С. 4-35.
2. Бухгольц Б.М. Smart Grids-основы и технологии энергосистем будущего: пер. с англ. / Б.М.Бухгольц, З.А.Стычински. М.: МЭИ, 2017. 460 с.
3. Стычински З. А. Возобновляемые источники энергии: Теоретические основы, технологии, технические характеристики, экономика / З. А. Стычински, Н. И. Воропай. – Magdeburg: Издательство Магдебургского университета имени Отто-фон-Герике (Otto-von- Guericke-Universität Magdeburg). docupoint GmbH, 2010. 209 с.
4. Capuano L. International energy outlook 2018 (IEO2018) //US Energy Information Administration (EIA): Washington, DC, USA. 2018. Т. 2018. С. 21.
5. Gruenspecht H. International energy outlook 2011 //Center for Strategic and International Studies – 2010. [Электронный ресурс]. – Режим доступа: https://www.eia.gov/pressroom/presentations/howard_09192011.pdf (Дата обращения 20.03.2019).
6. Lévy P. Z., Drossinos Y., Thiel C. The effect of fiscal incentives on market penetration of electric vehicles: A pairwise comparison of total cost of ownership //Energy Policy. 2017. Т. 105. С. 524-533.
7. Passenger car rate: The United Nations Economic Commission for Europe (UNECE) [Электронный ресурс]. – Режим доступа: <https://w3.unece.org/PXWeb/en/Charts?IndicatorCode=44#> (Дата обращения 20.03.2019).
8. World Population Prospects 2017: United Nations DESA / Population Division [Электронный ресурс]. – Режим доступа: <https://population.un.org/wpp/Download/Standard/Population> (Дата обращения 20.03.2019).
9. Макаров А. А., Митрова Т. А., Кулагин В. А. Долгосрочный прогноз развития энергетики мира и России //Экономический журнал Высшей школы экономики. 2012. Т. 16. №. 2. С. 172–204.
10. Статистический Ежегодник мировой энергетики 2020. [Электронный ресурс]. – Режим доступа: <https://yearbook.enerdata.ru> (Дата обращения 20.03.2020).

11. Irle R. Europe EV Sales for 2018: EV-volumes.com [Электронный ресурс]. – Режим доступа: <http://www.ev-volumes.com/country/total-euefta-plug-in-vehicle-volumes-2/> (Дата обращения 20.03.2019).
12. Aien M. et al. Probabilistic power flow of correlated hybrid wind-photovoltaic power systems //IET Renewable Power Generation. 2014. Т. 8. №. 6. С. 649-658.
13. Nikmehr N., Ravadanegh S. N. Heuristic probabilistic power flow algorithm for microgrids operation and planning //IET Generation, Transmission & Distribution. 2015. Т. 9. №. 11. С. 985-995.
14. Ishii T. et al. Estimation of the maximum power temperature coefficients of PV modules at different time scales //Solar Energy Materials and Solar Cells. 2011. Т. 95. №. 1. С. 386-389.
15. Fernandez L. P. et al. Assessment of the impact of plug-in electric vehicles on distribution networks //IEEE transactions on power systems. 2011. Т. 26. №. 1. С. 206-213.
16. Valseira-Naranjo E. et al. Deterministic and probabilistic assessment of the impact of the electrical vehicles on the power grid //2011 IEEE Power and Energy Society General Meeting. IEEE, 2011. С. 1-8.
17. Papadopoulos P. et al. Electric vehicles' impact on British distribution networks //IET Electrical Systems in Transportation. 2012. Т. 2. №. 3. С. 91-102.
18. Vlachogiannis J. G. Probabilistic constrained load flow considering integration of wind power generation and electric vehicles //IEEE Transactions on Power Systems. 2009. Т. 24. №. 4. С. 1808-1817.
19. Faridimehr S., Venkatachalam S., Chinnam R. B. A stochastic programming approach for electric vehicle charging network design //IEEE Transactions on Intelligent Transportation Systems. 2018. №. 99. С. 1-13.
20. Duan M. et al. A novel hybrid prediction model for aggregated loads of buildings by considering the electric vehicles //Sustainable Cities and Society. 2018. Т. 41. С. 205-219.
21. Zhao L. et al. Simulation methods for assessing electric vehicle impact on distribution grids //IEEE PES T&D 2010. IEEE, 2010. С. 1-7.
22. Lopes J. A. P., Soares F. J., Almeida P. M. R. Integration of electric vehicles in the electric power system //Proceedings of the IEEE. 2011. Т. 99. №. 1. С. 168-183.

23. Valsera-Naranjo E. et al. Deterministic and probabilistic assessment of the impact of the electrical vehicles on the power grid //2011 IEEE Power and Energy Society General Meeting. IEEE, 2011. C. 1-8.
24. Li G., Zhang X. P. Modeling of plug-in hybrid electric vehicle charging demand in probabilistic power flow calculations //IEEE Transactions on Smart Grid. 2012. T. 3. №. 1. C. 492-499.
25. Morshed M. J., Hmida J. B., Fekih A. A probabilistic multi-objective approach for power flow optimization in hybrid wind-PV-PEV systems //Applied energy. 2018. T. 211. C. 1136-1149.
26. Kempton W., Letendre S. E. Electric vehicles as a new power source for electric utilities //Transportation Research Part D: Transport and Environment. 1997. T. 2. №. 3. C. 157-175.
27. Hu J. et al. Electric vehicle fleet management in smart grids: A review of services, optimization and control aspects //Renewable and Sustainable Energy Reviews. 2016. T. 56. C. 1207-1226.
28. Mwasilu F. et al. Electric vehicles and smart grid interaction: A review on vehicle to grid and renewable energy sources integration //Renewable and sustainable energy reviews. 2014. T. 34. C. 501-516.
29. Tan K. M., Ramachandaramurthy V. K., Yong J. Y. Integration of electric vehicles in smart grid: A review on vehicle to grid technologies and optimization techniques //Renewable and Sustainable Energy Reviews. 2016. T. 53. C. 720-732.
30. Sortomme E., El-Sharkawi M. A. Optimal scheduling of vehicle-to-grid energy and ancillary services //IEEE Transactions on Smart Grid. 2012. T. 3. №. 1. C. 351-359.
31. Sortomme E., El-Sharkawi M. A. Optimal charging strategies for unidirectional vehicle-to-grid //IEEE Transactions on Smart Grid. 2011. T. 2. №. 1. C. 131-138.
32. Ghofrani M., Arabali A., Etezadi-Amoli M. Electric drive vehicle to grid synergies with large scale wind resources //2012 IEEE Power and Energy Society General Meeting. IEEE, 2012. C. 1-6.
33. Wang Z., Wang S. Grid power peak shaving and valley filling using vehicle-to-grid systems //IEEE Transactions on power delivery. 2013. T. 28. №. 3. C. 1822-1829.

34. Soares J. et al. Application-Specific Modified Particle Swarm Optimization for energy resource scheduling considering vehicle-to-grid //Applied Soft Computing. 2013. Т. 13. №. 11. С. 4264-4280.
35. Fazelpour F. et al. Intelligent optimization to integrate a plug-in hybrid electric vehicle smart parking lot with renewable energy resources and enhance grid characteristics //Energy Conversion and Management. 2014. Т. 77. С. 250-261.
36. Soares J. et al. Multi-objective parallel particle swarm optimization for day-ahead Vehicle-to-Grid scheduling //2013 IEEE Computational Intelligence Applications in Smart Grid (CIASG). IEEE, 2013. С. 138-145.
37. Saber A. Y., Venayagamoorthy G. K. Unit commitment with vehicle-to-grid using particle swarm optimization //2009 IEEE Bucharest PowerTech. IEEE, 2009. С. 1-8.
38. Saber A. Y., Venayagamoorthy G. K. Intelligent unit commitment with vehicle-to-grid – A cost-emission optimization //Journal of Power Sources. 2010. Т. 195. №. 3. С. 898-911.
39. Ghanbarzadeh T., Goleijani S., Moghaddam M. P. Reliability constrained unit commitment with electric vehicle to grid using hybrid particle swarm optimization and ant colony optimization //2011 IEEE Power and Energy Society General Meeting. IEEE, 2011. С. 1-7.
40. Ma Y. et al. Modeling the benefits of vehicle-to-grid technology to a power system //IEEE Transactions on power systems. 2012. Т. 27. №. 2. С. 1012-1020.
41. Горнштейн В.М. Наивыгоднейшее распределение нагрузок между параллельно работающими электростанциями. – М.: Госэнергоиздат, 1949. 256 с.
42. Маркович И.М. Энергетические системы и их режимы. – М.: Госэнергоиздат, 1952. - 312 с.
43. Фазылов Х.Ф. Теория и методы расчета электрических систем. – Ташкент: Изд-во АН УзССР. 1953. - 176 с.
44. Веников В.А., Идельчик В.И. Электрические станции, сети и системы. Методы оптимизации управления планированием больших систем энергетики // М. Высшая школа, 1974, С.201-205.
45. Фазылов Х.Ф., Юлдашев Х.Ю., Оптимизация режимов электрических сетей и систем // Ташкент: Фан, 1987, С.145-151.
46. Совалов С.А. Автоматизация управления энергообъединениями // М., Энергия, 1979, С. 432.

47. Понтрягин Л. С. Оптимальные процессы регулирования, УМН, 1959, том 14, выпуск 1(85), 3–20.
48. Беллман Р. Динамическое программирование. – под. ред //Воробьева ННМ: Иностран. литер. 1960. 458 с.
49. Крумм Л.А. Методы оптимизации при управлении электроэнергетическими системами // Новосибирск: Наука, 1981, С. 299-313.
50. Гамм А.З., Кучеров Ю.Н., Паламарчук С.И. Методы решения задач реального времени в электроэнергетике // Новосибирск: Наука, 1990, С 290-311.
51. Руденко Ю. Н. Автоматизированные системы диспетчерского управления ЕЭС СССР //Вестник Академии наук СССР. 1987. Т. 57. №. 10. С. 23-32.
52. Воропай Н.И., Ершевич В.В., Лугинский Я.Н. и др. Управление мощными энергообъединениями /Под ред. С.А. Савалова. М.: Энергоатомиздат. 1984. 255 с.
53. Гамм А.З., Крумм Л.А., Мурашко Н.А. и др. Система алгоритмов управления режимами Единой электроэнергетической системы. Кибернетика и моделирование в энергетике. М.: Наука, 1972. 238 с.
54. Войтов О.Н., Воронин О.П., Гамм А.З. и др. Автоматизированная система оперативно-диспетчерского управления электроэнергетическими системами. – Новосибирск: Наука, 1986. 201 с.
55. Нестеров Ю. Е. Введение в выпуклую оптимизацию. Москва : Изд-во МЦНМО, 2010. 280 с.
56. Дикин И.И. Исследование задач оптимального программирования методом внутренних точек //Методы оптимизации. 1975. С. 72.
57. Karmarkar N. A new polynomial-time algorithm for linear programming //Proceedings of the sixteenth annual ACM symposium on Theory of computing. 1984. С. 302-311.
58. K. Ponnambalam, V.H.Quintana and A Vannelli, “A Fast Algorithm For Power System Optimization Problems Using An Interior Point Method” // IEEE Trans. On Power Systems, Vol 7, No 2, May 1992. - P. 892-899.
59. Ponnambalam K., Quintana V. H., Vannelli A. A fast algorithm for power system optimization problems using an interior point method //IEEE Transactions on Power Systems. – 1992. Т.7. №. 2. С. 892-899.
60. Zorkaltsev V. I., Mokryi I. V. Interior point algorithms in linear optimization //Journal of Applied and Industrial Mathematics. 2018. Т. 12. №. 1. С. 191-199.
61. Prékopa A. Stochastic programming. – Springer Science & Business Media, 2013. 324 с.

62. Ben-Tal A., El Ghaoui L., Nemirovski A. Robust optimization. – Princeton University Press, 2009. T. 28.
63. Charnes A., Cooper W. W. Chance-constrained programming //Management science. 1959. T. 6. №. 1. C. 73-79.
64. Li P., Arellano-Garcia H., Wozny G. Chance constrained programming approach to process optimization under uncertainty //Computer Aided Chemical Engineering. 2006. T. 21. №. B. C. 1245.
65. Geletu A. et al. Advances and applications of chance-constrained approaches to systems optimisation under uncertainty //International Journal of Systems Science. 2013. T. 44. №. 7. C. 1209-1232.
66. Geletu A. et al. Monotony analysis and sparse-grid integration for nonlinear chance constrained process optimization //Engineering Optimization. 2011. T. 43. №. 10. C. 1019-1041.
67. Bienstock D., Chertkov M., Harnett S. Chance-constrained optimal power flow: Risk-aware network control under uncertainty //Siam Review. 2014. T. 56. №.3. C. 461-495.
68. Zhang Y., Shen S., Mathieu J. L. Distributionally robust chance-constrained optimal power flow with uncertain renewables and uncertain reserves provided by loads //IEEE Transactions on Power Systems. 2016. T. 32. №. 2. C. 1378-1388.
69. Pagnoncelli B. K., Ahmed S., Shapiro A. Sample average approximation method for chance constrained programming: theory and applications //Journal of optimization theory and applications. 2009. T. 142. №. 2. C. 399-416.
70. Zhang H., Li P. Chance constrained programming for optimal power flow under uncertainty //IEEE Transactions on Power Systems. 2011. T. 26. №. 4. C. 2417-2424.
71. Wendt M., Li P., Wozny G. Nonlinear chance-constrained process optimization under uncertainty //Industrial & engineering chemistry research. 2002. T. 41. №.15. C. 3621-3629.
72. Geletu A. et al. An inner-outer approximation approach to chance constrained optimization //SIAM Journal on Optimization. 2017. T. 27. №.3. C. 1834-1857.
73. Mohagheghi E. et al. Chance Constrained Optimal Power Flow Using the Inner-Outer Approximation Approach //2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe). IEEE, 2018. C. 1-6.

74. Bacher R., Van Meeteren H. P. Real-time optimal power flow in automatic generation control //IEEE Transactions on Power Systems. 1988. T.3. №. 4. C. 1518-1529.
75. Gan L., Low S. H. An online gradient algorithm for optimal power flow on radial networks //IEEE Journal on Selected Areas in Communications. 2016. T. 34. №. 3. C. 625-638.
76. Hong W. et al. A quasi-sequential approach to large-scale dynamic optimization problems //AIChE Journal. 2006. T.52. №. 1. C. 255-268.
77. Bartl M., Li P., Biegler L. T. Improvement of state profile accuracy in nonlinear dynamic optimization with the quasi-sequential approach //AIChE Journal. 2011. T. 57. №. 8. C. 2185-2197.
78. Li Z., Qiu F., Wang J. Data-driven real-time power dispatch for maximizing variable renewable generation //Applied Energy. 2016. T.170. C. 304-313.
79. Siano P. et al. Real time operation of smart grids via FCN networks and optimal power flow //IEEE Transactions on Industrial Informatics. 2012. T.8. №.4. C. 944-952.
80. Raja S., Fokoué E. Multi-Stage Fault Warning for Large Electric Grids Using Anomaly Detection and Machine Learning //arXiv preprint arXiv:1903.06700. 2019.
81. Yang J. et al. Prediction of Line Fault Based on Optimized Decision Tree //2018 International Conference on Computer Modeling, Simulation and Algorithm (CMSA 2018). Atlantis Press, 2018. C. 146-149.
82. Benkercha R., Moulahoum S. Fault detection and diagnosis based on C4. 5 decision tree algorithm for grid connected PV system //Solar Energy. – 2018. – T. 173. – C. 610-634.
83. Jindal A. et al. Decision tree and SVM-based data analytics for theft detection in smart grid //IEEE Transactions on Industrial Informatics. 2016. T. 12. №.3. C. 1005-1016.
84. Terzi D. S., Arslan B., Sagiroglu S. Smart grid security evaluation with a big data use case //2018 IEEE 12th International Conference on Compatibility, Power Electronics and Power Engineering (CPE-POWERENG 2018). IEEE, 2018. C. 1-6.
85. Aimal S. et al. Data Analytics for Electricity Load and Price Forecasting in the Smart Grid //Workshops of the International Conference on Advanced Information Networking and Applications. Springer, Cham, 2019. C. 582-591.

86. Yang J. et al. Prediction of Line Fault Based on Optimized Decision Tree //2018 International Conference on Computer Modeling, Simulation and Algorithm (CMSA 2018). Atlantis Press, 2018. C. 146-149.
87. Ho T. K. Random decision forests //Proceedings of 3rd international conference on document analysis and recognition. IEEE, 1995. T.1. C. 278-282.
88. Breiman L. Random forests //Machine learning. 2001. T.45. №1. C. 5-32.
89. Kleinberg E. M. On the algorithmic implementation of stochastic discrimination //IEEE Transactions on Pattern Analysis and Machine Intelligence. 2000. T. 22. №5. C. 473-490.
90. Zhukov A. et al. Ensemble methods of classification for power systems security assessment //Applied computing and informatics. 2019. T.15. №1. C. 45-53.
91. Tomin N. V. et al. Machine learning techniques for power system security assessment //IFAC-PapersOnLine. 2016. T.49. №27. C. 445-450.
92. Liu C. et al. Dynamic security assessment of western Danish power system based on ensemble decision trees. 2014. C. 12-78.
93. Rojas R. AdaBoost and the super bowl of classifiers a tutorial introduction to adaptive boosting //Freie University, Berlin, Tech. Rep. 2009. C. 1-6.
94. Schapire R. E. The boosting approach to machine learning: An overview //Non-linear estimation and classification. Springer, New York, NY, 2003. C. 149-171.
95. Gupta S. et al. Support-vector-machine-based proactive cascade prediction in smart grid using probabilistic framework //IEEE Transactions on Industrial Electronics. 2015. T.62. №4. C. 2478-2486.
96. Matic-Cuka B., Kezunovic M. Islanding detection for inverter-based distributed generation using support vector machine method //IEEE Transactions on Smart Grid. 2014. T.5. №6. C. 2676-2686.
97. Ozay M. et al. Machine learning methods for attack detection in the smart grid //IEEE transactions on neural networks and learning systems. 2016. T.27. №8. C. 1773-1786.
98. Shahid N. et al. Support vector machine based fault detection & classification in smart grids //2012 IEEE Globecom Workshops. IEEE, 2012. C. 1526-1531.
99. Shi J. et al. Forecasting power output of photovoltaic systems based on weather classification and support vector machines //IEEE Transactions on Industry Applications. 2012. T.48. №3. C. 1064-1069.
100. Sharma N. et al. Predicting solar generation from weather forecasts using machine learning //2011 IEEE international conference on smart grid communications (SmartGridComm). IEEE, 2011. C. 528-533.

101. Hong T. et al. Modeling and forecasting hourly electric load by multiple linear regression with interactions //IEEE PES General Meeting. IEEE, 2010. C.1-8.
102. Kramer O., Gieseke F. Short-term wind energy forecasting using support vector regression //Soft Computing Models in Industrial and Environmental Applications, 6th International Conference SOCO 2011. Springer, Berlin, Heidelberg, 2011. C. 271-280.
103. Wang J. et al. An annual load forecasting model based on support vector regression with differential evolution algorithm //Applied Energy. 2012. T.94. C.65-70.
104. Aung Z. et al. Towards accurate electricity load forecasting in smart grids //Proceedings of DBKDA. 2012. C. 51-57.
105. Gao W. et al. The Probabilistic Model and Forecasting of Power Load Based on Variational Bayesian Expectation Maximization and Relevance Vector Machine //Wireless Personal Communications. 2018. T.102. №4. C. 3041-3053.
106. Alamaniotis M., Bargiotas D., Tsoukalas L. H. Towards smart energy systems: application of kernel machine regression for medium term electricity load forecasting //SpringerPlus. 2016. T.5. №1. C. 58.
107. Bessa R. J. et al. Probabilistic solar power forecasting in smart grids using distributed information //International Journal of Electrical Power & Energy Systems. 2015. T.72. C. 16-23.
108. Alamaniotis M. et al. Genetic optimal regression of relevance vector machines for electricity pricing signal forecasting in smart grids //IEEE transactions on smart grid. 2015. T.6. №6. C. 2997-3005.
109. Alamaniotis M., Karagiannis G. Genetic driven multi-relevance vector regression forecasting of hourly wind speed in smart power systems. – 2018.
110. Kearns M. Learning Boolean formulae or finite automata is as hard as factoring //Technical Report TR-14-88 Harvard University Aikem Computation Laboratory. 1988. 24 c.
111. Friedman J. H. Greedy function approximation: a gradient boosting machine //Annals of statistics. 2001. C. 1189-1232.
112. Touzani S., Granderson J., Fernandes S. Gradient boosting machine for modeling the energy consumption of commercial buildings //Energy and Buildings. – 2018. T. 158. C. 1533-1543.
113. Madani S. S. et al. Islanding detection for PV and DFIG using decision tree and AdaBoost algorithm //2012 3rd IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe). IEEE, 2012. C. 1-8.

114. Vrablcová P. et al. Smart grid load forecasting using online support vector regression //Computers & Electrical Engineering. 2018. T. 65. C. 102-117.
115. Papadopoulos S., Karakatsanis I. Short-term electricity load forecasting using time series and ensemble learning methods //2015 IEEE Power and Energy Conference at Illinois (PECI). IEEE, 2015. C. 1-6.
116. Persson C. et al. Multi-site solar power forecasting using gradient boosted regression trees //Solar Energy. 2017. T. 150. C. 423-436.
117. Chatzis S. P., Demiris Y. The infinite-order conditional random field model for sequential data modeling //IEEE transactions on pattern analysis and machine intelligence. 2013. T. 35. №6. C. 1523-1534.
118. Guo H. Accelerated continuous conditional random fields for load forecasting //IEEE Transactions on Knowledge and Data Engineering. 2015. T. 27. №8. C. 2023-2033.
119. Qin T. et al. Global ranking using continuous conditional random fields //Advances in neural information processing systems. 2009. C. 1281-1288.
120. Kalman R. E. A new approach to linear filtering and prediction problems //Journal of basic Engineering. 1960. T. 82. №1. C. 35-45.
121. Haykin S. S. (ed.). Kalman filtering and neural networks. New York : Wiley, 2001. C. 221-269.
122. Debs A. S., Larson R. E. A dynamic estimator for tracking the state of a power system //IEEE Transactions on Power Apparatus and Systems. 1970. №7. C. 1670-1678.
123. Глазунова А.М., Колосок И.Н., Съемщиков Е.С. Обнаружение ошибочных данных в измерительной информации методами динамического оценивания состояния при управлении интеллектуальной энергосистемой // Электричество. №2. 2017. С.18-27.
124. Glazunova A. Dynamic State Estimation of Electric Power System Integrating Wind Power Generation //E3S Web of Conferences. EDP Sciences, 2018. T. 69. C. 02013.
125. Ghahremani E., Kamwa I. Dynamic state estimation in power system by applying the extended Kalman filter with unknown inputs to phasor measurements //IEEE Transactions on Power Systems. 2011. T. 26. №4. C. 2556-2566.
126. Гамм А. З. и др. Методы прогнозирования параметров режима электроэнергетических систем для целей мониторинга и управления //Электричество. 2011. №5. С. 17-26.

127. Shih K. R., Huang S. J. Application of a robust algorithm for dynamic state estimation of a power system //IEEE Transactions on Power Systems. 2002. Т. 17. №1. С. 141-147.
128. Valverde G., Terzija V. Unscented Kalman filter for power system dynamic state estimation //IET generation, transmission & distribution. 2011. Т. 5. №1. С. 29-37.
129. Terejanu G. A. Unscented Kalman filter tutorial //University at Buffalo, Buffalo. 2011. 6 с.
130. Uhlmann J. K. Dynamic map building and localization: New theoretical foundations : дис. Oxford : University of Oxford, 1995. С. 9-68.
131. Sivanandam S. N., Deepa S. N. Genetic algorithms //Introduction to genetic algorithms. – Springer, Berlin, Heidelberg, 2008. – С. 15-37.
132. Jafari S., Darabad M. R., Golpayegani S. M. R. H. Is Genetic Algorithm As Efficient As Supposed? 13 с.
133. Irpan A. Deep reinforcement learning doesn't work yet. [Электронный ресурс]. – Режим доступа: <https://www.alexirpan.com/2018/02/14/rl-hard.html> (Дата обращения 10.05.2019).
134. Han M. et al. A review of reinforcement learning methodologies on control systems for building energy. 2018. С. 300-312.
135. Henderson P. et al. Deep reinforcement learning that matters //Thirty-Second AAAI Conference on Artificial Intelligence. 2018. С. 3207-3214.
136. Berlink H., Costa A. H. R. Batch reinforcement learning for smart home energy management //Twenty-Fourth International Joint Conference on Artificial Intelligence. 2015. С.2561-2567.
137. Mocanu E. et al. On-line building energy optimization using deep reinforcement learning //IEEE transactions on smart grid. 2018. Т. 10. №4. С. 3698-3708.
138. Venayagamoorthy G. K. et al. Dynamic energy management system for a smart microgrid //IEEE transactions on neural networks and learning systems. 2016. Т. 27. №8. С. 1643-1656.
139. Mbuwir B. V., Kaffash M., Deconinck G. Battery Scheduling in a Residential Multi-Carrier Energy System Using Reinforcement Learning //2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm). IEEE, 2018. С. 1-6.
140. Mbuwir B. et al. Reinforcement Learning-Based Battery Energy Management in a Solar Microgrid //Energy-Open. 2017. Т. 2. №4. С. 36.

141. Qiu X., Nguyen T. A., Crow M. L. Heterogeneous energy storage optimization for microgrids //IEEE Transactions on Smart Grid. 2016. Т. 7. №3. С. 1453-1461.
142. Wang H. et al. Reinforcement learning in energy trading game among smart microgrids //IEEE Transactions on Industrial Electronics. 2016. Т. 63. №. 8. С. 5109-5119.
143. Kim B. G. et al. Dynamic pricing and energy consumption scheduling with reinforcement learning //IEEE Transactions on Smart Grid. 2016. Т. 7. №5. С. 2187-2198.
144. Li D., Jayaweera S. K. Machine-learning aided optimal customer decisions for an interactive smart grid //IEEE Systems Journal. 2015. Т. 9. №4. С. 1529-1540.
145. Liu W. et al. A decision making strategy for generating unit tripping under emergency circumstances based on deep reinforcement learning //Proceedings of the CSEE. 2018. Т. 38. №1. С. 109-119.
146. Fjodor van Veen. The neural network zoo, September 2016. [Электронный ресурс]. - Режим доступа: <http://www.asimovinstitute.org/neural-network-zoo/> (Дата обращения 24.03.2019).
147. Хайкин С. Нейронные сети: полный курс, 2-е издание. Издательский дом Вильямс, 2008. 1103 с.
148. Николенко С., Кадурын А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей //СПб.: Питер. 2018. 480 с.
149. Zeiler M. D. et al. Deconvolutional networks //2010 IEEE Computer Society Conference on computer vision and pattern recognition. IEEE, 2010. С. 2528-2535.
150. Zahid M. et al. Electricity price and load forecasting using enhanced convolutional neural network and enhanced support vector regression in smart grids //Electronics. 2019. Т. 8. №. 2. С. 122.
151. Huang G. B., Zhu Q. Y., Siew C. K. Extreme learning machine: theory and applications //Neurocomputing. 2006. Т. 70. №1-3. С. 489-501.
152. Yang L., Li Y., Li Z. Improved-ELM method for detecting false data attack in smart grid //International Journal of Electrical Power & Energy Systems. 2017. Т. 91. С. 183-191.
153. Naz A. et al. Short-Term Electric Load and Price Forecasting Using Enhanced Extreme Learning Machine Optimization in Smart Grids //Energies. 2019. Т. 12. №5. С. 866.

154. Maass W. Liquid state machines: motivation, theory, and applications //Computability in context: computation and logic in the real world. 2011. C. 275-296.
155. Goodfellow I. NIPS 2016 tutorial: Generative adversarial networks //arXiv preprint arXiv:1701.00160. 2016. 57 c.
156. Förderer K. et al. Towards the modeling of flexibility using artificial neural networks in energy management and smart grids: note //Proceedings of the Ninth International Conference on Future Energy Systems. ACM, 2018. C. 85-90.
157. Greff K. et al. LSTM: A search space odyssey //IEEE transactions on neural networks and learning systems. 2017. T. 28. №10. C. 2222-2232.
158. Graves A. Practical variational inference for neural networks //Advances in neural information processing systems. 2011. C. 2348-2356.
159. Blundell C. et al. Weight uncertainty in neural networks //arXiv preprint arXiv:1505.05424. 2015. 10 c.
160. Wainwright M. J. et al. Graphical models, exponential families, and variational inference //Foundations and Trends® in Machine Learning. 2008. T. 1. №1–2. C. 1-305.
161. Fortunato M., Blundell C., Vinyals O. Bayesian recurrent neural networks //arXiv preprint arXiv:1704.02798. 2017. 14 c.
162. Chen K. et al. Short-term load forecasting with deep residual networks //IEEE Transactions on Smart Grid. 2018. T. 10. №4. C. 3943-3952.
163. He K. et al. Deep residual learning for image recognition //Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. C. 770-778.
164. Graves A., Wayne G., Danihelka I. Neural Turing machines //arXiv preprint arXiv:1410.5401. 2014. 26 c.
165. Hochreiter S., Schmidhuber J. Long short-term memory //Neural computation. 1997. T. 9. №8. C. 1735-1780.
166. Gers F. A., Schmidhuber J. Recurrent nets that time and count //Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium. IEEE, 2000. T. 3. C. 189-194.
167. Manitsas E. et al. Distribution system state estimation using an artificial neural network approach for pseudo measurement modeling //IEEE Transactions on Power Systems. 2012. T. 27. №4. C. 1888-1896.
168. Ashraf S. M. et al. Voltage stability monitoring of power systems using reduced network and artificial neural network //International Journal of Electrical Power & Energy Systems. 2017. T. 87. C. 43-51.

169. Glavic M., Fonteneau R., Ernst D. Reinforcement learning for electric power system decision and control: Past considerations and perspectives //IFAC-PapersOnLine. 2017. Т. 50. №1. С. 6918-6927.
170. Mocanu E. et al. Deep Learning for Power System Data Analysis // chapter in book Arghandeh R., Zhou Y. (ed.). Big Data Application in Power Systems. Elsevier, 2017. , С.125-158
171. Hernández L. et al. Artificial neural networks for short-term load forecasting in microgrids environment //Energy. 2014. Т. 75. С. 252-264.
172. Mosbah H., El-Hawary M. E. Optimization of neural network parameters by Stochastic Fractal Search for dynamic state estimation under communication failure //Electric Power Systems Research. 2017. Т. 147. С. 288-301.
173. Манусов В. З., Бирюков Е. В. Краткосрочное прогнозирование электрической нагрузки на основе нечеткой нейронной сети и ее сравнение с другими методами //Известия Томского политехнического университета. Инжиниринг георесурсов. 2006. Т. 309. №6. С. 153-158.
174. Манусов В. З., Хохлова С. В. Сравнительный анализ двух моделей прогнозирования электрической нагрузки промышленных предприятий, построенных на основе регрессионного анализа и искусственных нейронных сетей //Научный вестник Новосибирского государственного технического университета. 2008. №1. С. 147-159.
175. Курбацкий В.Г., Томин Н.В. Использование методов искусственного интеллекта в задачах планирования расходов электрической и тепловой энергий //Energetica Moldovei. Aspecte regionale de dezvoltare. 2005. С. 437-444.
176. Гамм А. З. и др. Методы прогнозирования параметров режима электроэнергетических систем для целей мониторинга и управления //Электричество. 2011. №5. С. 17-26.
177. Васильев Д. А., Колоколов М. В. Модели автоматизированного прогнозирования электрических нагрузок промышленных предприятий //Управление большими системами: сборник трудов. 2011. №34. С.254-266.
178. Мороз А. Н. и др. Нейро-сетевое моделирование в задачах прогнозирования режимов работы электрических сетей //Электротехника и электромеханика. 2016. №1. С.65-68.
179. Андросов В. М. Прогнозирование почасового электропотребления с использованием искусственных нейронных сетей. // Актуальные проблемы энергетики. 2018. С. 375-376.

180. Приходько И. А., Анушина Е. С. Современные подходы и методы прогнозирования электропотребления //Известия СПбГЭТУ "ЛЭТИ". 2005. С. 37.
181. Анушина Е. С. Прогнозирование временных рядов на основе интеллектуальных вычислительных технологий //Информатика и системы управления. 2009. №1. С. 84-90.
182. Marino D. L., Amarasinghe K., Manic M. Building energy load forecasting using deep neural networks //Industrial Electronics Society, IECON 2016-42nd Annual Conference of the IEEE. IEEE, 2016. С. 7046-7051.
183. Jozefowicz R., Zaremba W., Sutskever I. An empirical exploration of recurrent network architectures //International Conference on Machine Learning. 2015. С. 2342-2350.
184. Pan Z. et al. Data-Driven EV Load Profiles Generation Using a Variational Auto-Encoder //Energies. 2019. Т. 12. №5. С. 849.
185. Barbeiro P. N. P. et al. State estimation in distribution smart grids using autoencoders //2014 IEEE 8th International Power Engineering and Optimization Conference (PEOCO2014). IEEE, 2014. С. 358-363.
186. Gensler A. et al. Deep Learning for solar power forecasting—An approach using AutoEncoder and LSTM Neural Networks //2016 IEEE international conference on systems, man, and cybernetics (SMC). IEEE, 2016. С. 002858-002865.
187. Dedinec A. et al. Deep belief network based electricity load forecasting: An analysis of Macedonian case //Energy. 2016. Т. 115. С. 1688-1700.
188. Zhang X. et al. Short-term load forecasting based on a improved deep belief network //2016 International Conference on Smart Grid and Clean Energy Technologies (ICSGCE). IEEE, 2016. С. 339-342.
189. Marler R. T., Arora J. S. Survey of multi-objective optimization methods for engineering //Structural and multidisciplinary optimization. 2004. Т. 26. №. 6. С. 369-395.
190. Vincent T. L., Grantham W. J. Optimality in parametric systems (Book) //New York, Wiley-Interscience, 1981. 257 с.
191. Proos K. A. et al. Multicriterion evolutionary structural optimization using the weighting and the global criterion methods //AIAA journal. 2001. Т. 39. №10. С. 2006-2012.
192. Koski J., Silvennoinen R. Norm methods and partial weighting in multicriterion optimization of structures //International Journal for Numerical Methods in Engineering. 1987. Т. 24. №6. С. 1101-1121.

193. Rentmeesters M. J., Tsai W. K., Lin K. J. A theory of lexicographic multi-criteria optimization //Proceedings of ICECCS'96: 2nd IEEE International Conference on Engineering of Complex Computer Systems (held jointly with 6th CSES AW and 4th IEEE RTAW). IEEE, 1996. C. 76-79.
194. Tseng C. H., Lu T. W. Minimax multiobjective optimization in structural design //International Journal for Numerical Methods in Engineering. 1990. T. 30. №6. C. 1213-1228.
195. Athan T. W., Papalambros P. Y. A note on weighted criteria methods for compromise solutions in multi-objective optimization //Engineering optimization. – 1996. T. 27. №2. C. 155-176.
196. Gerasimov E. N., Repko V. N. Multicriterial optimization //International Applied Mechanics. 1978. T. 14. №11. C. 1179-1184.
197. Lee S. M. et al. Goal programming for decision analysis. – Philadelphia : Auerbach Publishers, 1972. C. 252-260.
198. Messac A. Physical programming-effective optimization for computational design //AIAA journal. 1996. T. 34. №1. C. 149-158.
199. Santy T. L. The analytical hierarchy process: Planning, priority setting, resource allocation //Decision Making Series, McGraw Hill, New York, USA. 1980. C.161-176.
200. Borkowska B. Probabilistic load flow //IEEE Transactions on Power Apparatus and Systems. 1974. №3. C. 752-759.
201. Meliopoulos A. P. S., Cokkinides G. J., Chao X. Y. A new probabilistic power flow analysis method //IEEE Transactions on Power Systems. 1990. T. 5. №1. C. 182-190.
202. Fan M. et al. Probabilistic power flow studies for transmission systems with photovoltaic generation using cumulants //IEEE Transactions on Power Systems. 2012. T. 27. №4. C. 2251-2261.
203. Liu C. et al. Probabilistic power flow analysis using multidimensional holomorphic embedding and generalized cumulants //IEEE Transactions on Power Systems. 2018. T. 33. №6. C. 7132-7142.
204. Hajian, Mahdi, William D. Rosehart, and Hamidreza Zareipour. Probabilistic power flow by Monte Carlo simulation with Latin supercube sampling// IEEE Transactions on Power Systems. T.28.2. 2013. C. 1550-1559.
205. Momoh J. A. Electric power system applications of optimization. - CRC press, 2008. 608 c.

206. Byrd R. H. et al. A limited memory algorithm for bound constrained optimization //SIAM Journal on Scientific Computing. 1995. Т. 16. №5. С. 1190-1208.
207. Chaturvedi A., Prasad K., Ranjan R. Use of interval arithmetic to incorporate the uncertainty of load demand for radial distribution system analysis //IEEE transactions on power delivery. 2006. Т. 21. №2. С. 1019-1021.
208. Шарый С. П. Конечномерный интервальный анализ //Новосибирск: Издательство “XYZ”. 2019. С. 403-404.
209. Лопатин А. С. Метод отжига //Стохастическая оптимизация в информатике. 2005. Т. 1. №1. С. 133-139.
210. Ingber L. Very fast simulated re-annealing //Mathematical and computer modelling. 1989. Т. 12. №8. С. 967-973.
211. Lavaei J., Low S. H. Zero duality gap in optimal power flow problem //IEEE Transactions on Power Systems. 2012. Т. 27. №1. С. 92-107.
212. Wei H. et al. An interior point nonlinear programming for optimal power flow problems with a novel data structure //IEEE Transactions on Power Systems. 1998. Т. 13. №3. С. 870-877.
213. Lin W. M., Huang C. H., Zhan T. S. A hybrid current-power optimal power flow technique //IEEE Transactions on Power Systems. 2008. Т. 23. №1. С. 177-185.
214. Jiang Q. Y. et al. Power–current hybrid rectangular formulation for interior-point optimal power flow //IET generation, transmission & distribution. 2009. Т. 3. №8. С. 748-756.
215. Gan D., Thomas R. J., Zimmerman R. D. Stability-constrained optimal power flow //IEEE Transactions on Power Systems. 2000. Т. 15. №2. С. 535-540.
216. Cai H. R., Chung C. Y., Wong K. P. Application of differential evolution algorithm for transient stability constrained optimal power flow //IEEE Transactions on Power Systems. 2008. Т. 23. №2. С. 719-728.
217. Bai X. et al. Semidefinite programming for optimal power flow problems //International Journal of Electrical Power & Energy Systems. 2008. Т. 30. №6-7. С. 383-392.
218. Low S. H. Convex relaxation of optimal power flow—Part I: Formulations and equivalence //IEEE Transactions on Control of Network Systems. 2014. Т. 1. №1. С. 15-27.
219. Malherbe C., Vayatis N. Global optimization of lipschitz functions //Proceedings of the 34th International Conference on Machine Learning-Volume 70. – JMLR.org, 2017. С. 2314-2323.

220. Armand P., Ségalat P. A limited memory algorithm for inequality constrained minimization. – Technical Report 2003-08, University of Limoges (France). 2003. 15 с.
221. Liu D. C., Nocedal J. On the limited memory BFGS method for large scale optimization //Mathematical programming. 1989. Т. 45. №1-3. С. 503-528.
222. Gilbert J. C., Lemaréchal C. Some numerical experiments with variable-storage quasi-Newton algorithms //Mathematical programming. 1989. Т. 45. №1-3. С. 407-435.
223. Valls V., Leith D. J. A convex optimization approach to discrete optimal control //IEEE Transactions on Automatic Control. 2018. Т. 64. №1. С. 35-50.
224. Yu J. et al. A quasi-Newton approach to nonsmooth convex optimization problems in machine learning //Journal of Machine Learning Research. 2010. Т. 11. №. Mar. С. 1145-1200.
225. Гамм А.З. Статистические методы оценивания состояния электроэнергетических систем. Наука, 1976. 220 с.
226. Singh H., Alvarado F. L. Weighted least absolute value state estimation using interior point methods //IEEE Transactions on Power Systems. 1994. Т. 9. №3. С. 1478-1484.
227. АНАРЭС - комплекс программ для моделирования режимов энергосистем, [Электронный ресурс]. - Режим доступа: <http://anares.ru/software> (Дата обращения 13.10.2019).
228. Abarbanel H. Analysis of observed chaotic data. – Springer Science & Business Media, 2012. 272 с.
229. Лоскутов А. Ю. Математические основы хаотических динамических систем: курс лекций //М.: МГУ. 2008. 78 с.
230. Takens F. On the numerical determination of the dimension of an attractor //Dynamical systems and bifurcations. – Springer, Berlin, Heidelberg, 1985. С. 99-106.
231. Noakes L. The Takens embedding theorem //International Journal of Bifurcation and Chaos. 1991. Т. 1. №04. С. 867-872.
232. Rosenstein M. T., Collins J. J., De Luca C. J. A practical method for calculating largest Lyapunov exponents from small data sets //Physica D: Nonlinear Phenomena. 1993. Т. 65. №1-2. С. 117-134.
233. TISEAN Nonlinear Time Series Analysis, [Электронный ресурс]. - Режим доступа: <https://www.pks.mpg.de/~tisean/> (Дата обращения 20.10.2019)

234. Песин Я. Б. Характеристические показатели Ляпунова и гладкая эргодическая теория //Успехи математических наук. 1977. Т. 32. №4 (196). С. 55-112.
235. Glazunova A. Dynamic state estimation //Monitoring, Control and Protection of Interconnected Power Systems. – Springer, Berlin, Heidelberg, 2014. С. 107-123.
236. Система сбора и передачи данных АНАРЭС-ССПИ, [Электронный ресурс]: <http://anares.ru/sspi> (Дата обращения 03.10.2019).
237. Kingma D. P., Ba J. Adam: A method for stochastic optimization //arXiv preprint arXiv:1412.6980. – 2014. 15 с.
238. Gorban A. N. et al. (ed.). Principal manifolds for data visualization and dimension reduction. Berlin : Springer, 2008. Т. 58. С. 96-130.
239. Monticelli A. State estimation in electric power systems: a generalized approach. - Springer Science & Business Media, 2012. 394 с.
240. Болоев Е. В. и др. Вероятностный анализ переменных режима электроэнергетической системы //Электричество. 2014. №1. С. 12-20.
241. Sengupta S., Basak S., Peters R. A. Particle Swarm Optimization: A survey of historical and recent developments with hybridization perspectives //Machine Learning and Knowledge Extraction. 2019. Т. 1. №1. С. 157-191.
242. Huang C. M. et al. Comparative study of evolutionary computation methods for active–reactive power dispatch //IET generation, transmission & distribution. 2012. Т.6. №7. С. 636-645.
243. Браммер К., Зиффлинг Г. Фильтр Калмана-Бьюси: детерминированное наблюдение и стохастическая фильтрация. Наука, 1982. С. 87-88.
244. Sperstad I. B., Korpås M. Energy storage scheduling in distribution systems considering wind and photovoltaic generation uncertainties //Energies. 2019. Т. 12. №7. С. 1231.
245. Zaferanlouei S. et al. Computational efficiency assessment of multi-period AC optimal power flow including energy storage systems //2018 International Conference on Smart Energy Systems and Technologies (SEST). IEEE, 2018. С. 1-6.
246. Kourounis D., Fuchs A., Schenk O. Toward the next generation of multiperiod optimal power flow solvers //IEEE Transactions on Power Systems. 2018. Т. 33. №4. С. 4005-4014.
247. Gopalakrishnan A. et al. Global optimization of multi-period optimal power flow //2013 American Control Conference. IEEE, 2013. С. 1157-1164.

248. Levron Y., Guerrero J. M., Beck Y. Optimal power flow in microgrids with energy storage //IEEE Transactions on Power Systems. 2013. Т. 28. №3. С. 3226-3234.
249. Grillo S., Pievatolo A., Tironi E. Optimal storage scheduling using Markov decision processes //IEEE Transactions on Sustainable Energy. 2015. Т. 7. №2. С. 755-764.
250. Faber R., Jockenhövel T., Tsatsaronis G. Dynamic optimization with simulated annealing //Computers & chemical engineering. 2005. Т. 29. №2. С. 273-290.
251. Mohagheghi E. et al. Real-time active-reactive optimal power flow with flexible operation of battery storage systems //Energies. 2020. Т. 13. №7. С. 1697.

Список публикаций соискателя по теме диссертационной работы

Рекомендованные ВАК РФ по специальности 05.14.02 при Минобрнауки России:

- A1. Домышев А.В. Стохастический метод для оптимального управления нормальными электрическими режимами энергосистем // Энергетик, 2021, №1, С. 11-14.
- A2. Воропай Н.И., Ефимов Д.Н., Домышев А.В., Осак А.Б., Панасецкий Д.А. Анализ условий функционирования будущей электроэнергетической системы при рассматриваемом сценарии ее развития // Электроэнергия. Передача и распределение, 2020, №6 (63), С. 34-38.
- A3. Домышев А.В., Крупнев Д.С. Оценка режимной надёжности электроэнергетических систем на основе метода Монте-Карло // Электричество, 2015, №2, С. 4-11.

Рекомендованные ВАК РФ по другим специальностям:

- A4. Домышев А.В. Оптимизация электрических сетей со стохастическими элементами, Журнал СФУ. Техника и технологии, 2020 13(2), С.406-419.
- A5. Домышев А. В. Раскладка на плоскости и кластеризация графа, представляющего собой электрическую сеть //Cloud of science. - 2018. - Т. 5. - №. 2, С. 341-350.
- A6. Шаповало А.А., Коноплев Т.Ф., Домышев А.В., Замула К.В., Сербин Ю.В. Перспективы применения интеллектуальных систем автоматического регулирования напряжения в территориально распределенных децентрализованных системах электроснабжения газового комплекса России // Газовая промышленность, 2020, №8, С. 14-22.

Индексируемые SCOPUS и Web Of Science:

- A7. Domyshev A.V., Osak A., Zamula K. Flexible hierarchical system of automatic voltage control, EPJ Web of Conferences. 2019. С. 01002.
- A8. Domyshev A.V., Sidorov D., Panasetsky D., Ju P., Wu F., Sun Y. Optimal power flow calculation using BFGS-based optimisation scheme, 2nd IEEE Conference on Energy Internet and Energy System Integration, EI2 2018 - Proceedings 2. 2018. С. 8582375.
- A9. Mahfoud R.J., Sun Y., Alkayem N.F., Domyshev A.V., Panasetsky D., Sidorov D. Power losses minimization in radial distribution networks by capacitor allocation using hybrid evolutionary computation technique, 2nd IEEE Conference on Energy Internet and Energy System Integration, EI2 2018 - Proceedings 2. 2018. С. 8582451.

Главы в монографиях:

- A10. Domyshev A. et al. Resilient future energy systems: smart grids, vehicle-to-grid, and microgrids // Solving Urban Infrastructure Problems Using Smart City Technologies, edited by Vacca J. – Elsevier. – С. 571-597.
- A11. Домышев А.В., Осак А.Б., Панасецкий Д.А. Методы и подходы построения комплекса автоматического иерархического управления источниками реактивной мощности в нормальных и послеаварийных режимах ЭЭС // Иерархическое моделирование систем энергетики, отв. ред. Воропай Н.И., Стенников В.А. – Новосибирск: Академическое изд-во «Гео», 2020. С. 263-271.
- A12. Воропай Н.И., Домышев А.В., Осак А.Б. Анализ условий функционирования будущих электроэнергетических систем // Обоснование развития электроэнергетических систем: методология, модели, методы, их использование. – Новосибирск: Наука, 2015 – С. 328-335.
- A13. Воропай Н.И., Домышев А.В., Жуков А.В., Осак А.Б., Курбацкий В.Г., Томин Н.В. Исследование режимной надежности ЭЭС // Комплекс интеллектуальных средств для предотвращения крупных аварий в электроэнергетических системах. – Новосибирск: Наука, 2016 – С. 75-121.
- A14. Воропай Н.И., Домышев А.В., Непомнящий В.А. Модели и методы исследования режимной надежности электроэнергетических систем // Надежность систем энергетики: Проблемы и методы их решения, отв. ред. Воропай Н.И. – Новосибирск: Наука, 2014 – С. 57-73.

Прочие:

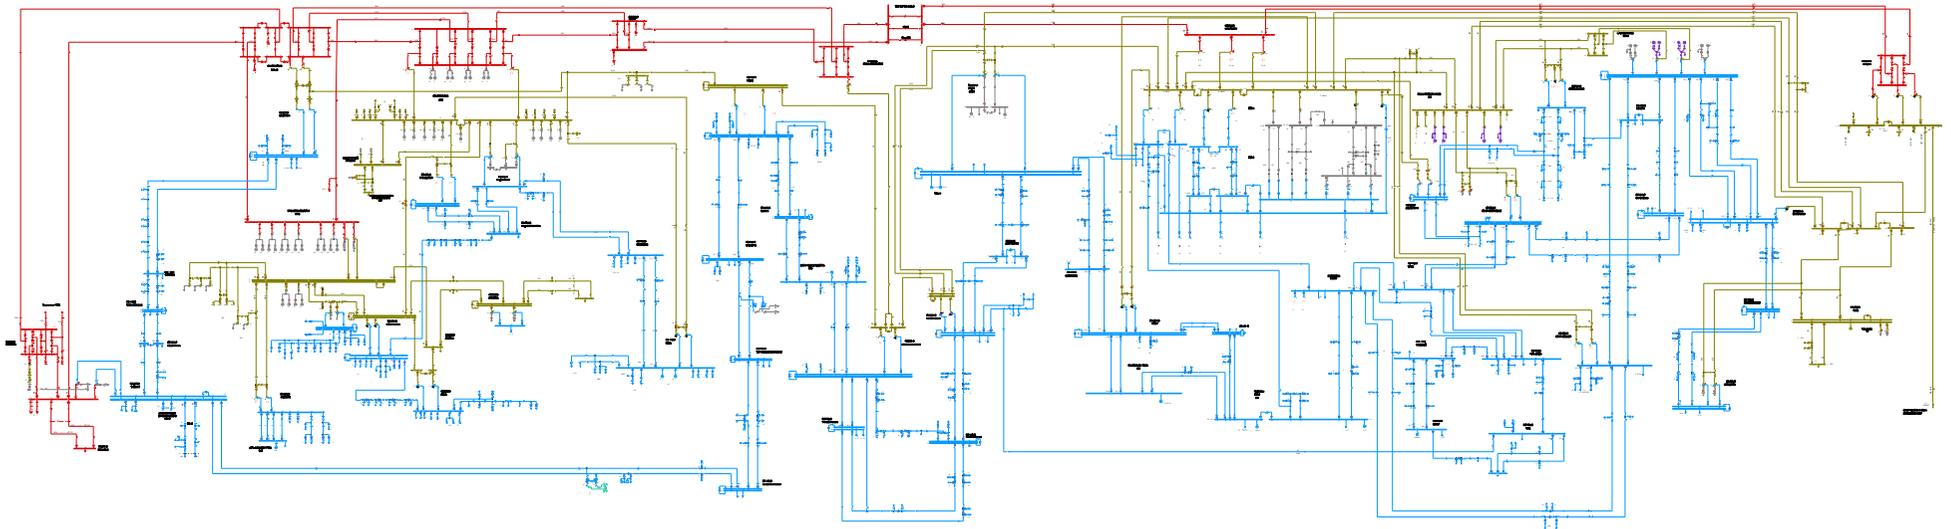
- A15. Домышев А.В. Оценивание состояния ЭЭС с использованием глубокого обучения, XIII Всероссийское совещание по проблемам управления ВСПУ-2019 Сборник трудов XIII Всероссийского совещания по проблемам управления ВСПУ-2019. Институт проблем управления им. В.А. Трапезникова РАН. 2019. С. 2107-2113.
- A16. Домышев А.В. Нейро-аналитические сети для оценивания состояния и прогнозирования параметров ЭЭС, Методические вопросы исследования надежности больших систем энергетики Международный научный семинар им. Ю.Н.Руденко, 91-е заседание семинара на тему «Методические и практические проблемы надежности систем энергетики», в 2-х книгах. Отв. ред. Н.И. Воропай. 2019. С. 295-304.
- A17. Томин Н.В., Курбацкий В.Г., Домышев А.В. Разработка интеллектуальной системы поддержки принятия решений "Искусственный диспетчер" на базе технологии глубокого машинного обучения с подкреплением, Методические вопросы исследования надежности больших систем энергетики Международный научный семинар им. Ю.Н.Руденко, 91-е заседание семинара на тему «Методические и практические проблемы надежности систем энергетики», в 2-х книгах. Отв. ред. Н.И. Воропай. 2019. С. 305-314.
- A18. Домышев А.В., Осак А.Б., Панасецкий Д.А. Методы и подходы построения комплекса автоматического иерархического управления источниками реактивной мощности в нормальных и послеаварийных режимах ЭЭС, Методические вопросы исследования надежности больших систем энергетики Международный научный семинар им. Ю.Н.Руденко, 91-е заседание семинара на тему «Методические и практические проблемы надежности систем энергетики», в 2-х книгах. Отв. ред. Н.И. Воропай. 2019. С. 315-323.
- A19. Домышев А.В. Оценивание состояния ЭЭС с использованием глубокого обучения, Прикладные задачи математики Материалы XXVI международной научно-технической конференции. Севастоп. гос. ун-т; науч. ред. С.О. Папков. 2018. С. 183-184.
- A20. Домышев А.В. Применение метода оптимизации BFGS для оптимизации режимов электроэнергетических систем, Методические вопросы исследования надежности больших систем энергетики Международный

научный семинар им. Ю.Н. Руденко: В 2-х книгах. Ответственный редактор Воропай Н.И.. 2018. С. 150-158.

ПРИЛОЖЕНИЕ 1

Схема тестовой ЭЭС

Рассматриваемая модель энергосистемы включает электрические сети Иркутской области напряжением 500 кВ - 110кВ. Генераторы в модели в основном заданы узлами того напряжения, на котором фактически работают соответствующие генераторы (6 кВ – 15 кВ). Некоторая генерация представлена в виде эквивалентных генераторов на шинах высокого или среднего напряжения. Нагрузка в основном задана на низкой стороне трансформаторов или на отпайке линий электропередачи. Генераторных узлов в модели – 486, нагрузочных – 485. Общее количество узлов в модели узлы/ветви для этой системы – **1248**, ветвей – **1481**.



ПРИЛОЖЕНИЕ 2

Пример результатов оптимизации за месяц

Дата/время	Снижение потерь, МВт	Снижение отклонения U, о.е.	Суммарное снижение потерь (дин.), МВт	Суммарное снижение потерь, МВт	Параметр (РПН)	Значение (номер отпайки)
01.01.2020 0:00	0,0809094	-0,223199	0,0809094	0,0809094		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
01.01.2020 4:30	0,166209	-0,347498	0,834078	0,834078		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
02.01.2020 2:00	0,00846916	-0,531146	6,312	6,312		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
02.01.2020 3:00	0,155506	-0,324923	6,42058	6,42058		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
02.01.2020 12:30	0,149576	-0,330881	7,20458	7,35415		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9

					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
02.01.2020 21:00	0,162724	-0,342088	9,37782	9,52739		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
02.01.2020 22:00	0,206711	-0,394279	9,76547	9,91505		
					Заводская АТ-1	16
03.01.2020 10:30	0,00399124	-0,528108	11,9246	12,0781		
					Шелехово АТ-8	7
					Ключи АТ-1	6
					Ключи АТ-2	6
					Ключи АТ-3	6
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
03.01.2020 11:00	0,275015	-0,438006	12,1996	12,3531		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
03.01.2020 12:00	-0,239106	-0,542839	12,1759	12,3295		
					УП-15 АТ-2	10
					ТЭЦ-11 АТ-1	7
					ТЭЦ-11 АТ-2	7
					Н.Зиминская АТ-1	10
					Н.Зиминская АТ-2	10
03.01.2020 12:30	-0,17185	-0,300979	12,004	12,1576		
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
03.01.2020 13:00	0,119765	-0,316187	12,1238	12,2774		

					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
03.01.2020 19:00	0,237712	-0,419083	13,6856	13,8391		
					Ключи АТ-1	6
					Ключи АТ-2	6
					Ключи АТ-3	6
03.01.2020 21:30	0,0438761	-0,0605038	14,1717	14,3253		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
04.01.2020 11:30	0,16759	-0,344561	13,8199	14,1411		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
04.01.2020 20:00	0,312242	-0,507659	16,2189	16,54		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
04.01.2020 21:00	-0,22199	-0,387602	16,2759	16,5971		
					УП-15 АТ-2	10
					ТЭЦ-11 АТ-1	7
					ТЭЦ-11 АТ-2	7
05.01.2020 10:30	0,0563544	-0,077541	17,2331	17,6106		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7

					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
05.01.2020 11:00	0,180537	-0,371879	17,4136	17,7912		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
05.01.2020 11:30	0,00795559	-0,273752	17,4216	17,7991		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
05.01.2020 12:30	0,151078	-0,343399	17,7334	18,1109		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
05.01.2020 13:00	0,13417	-0,315324	17,8676	18,2451		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
05.01.2020 19:00	0,217456	-0,426883	19,381	19,7585		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
05.01.2020 20:00	0,0300472	-0,0368658	19,5893	19,9668		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
06.01.2020 10:00	0,120984	-0,293272	21,45	21,9485		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
06.01.2020 13:30	0,0381175	-0,178254	22,2455	22,744		

					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
					УП-15 АТ-1	10
					УП-15 АТ-2	10
					ТЭЦ-11 АТ-1	7
					ТЭЦ-11 АТ-2	7
					Н.Зиминская АТ-1	11
					Н.Зиминская АТ-2	10
					Тулун АТ-1	5
					Тайшет АТ-1	7
					Тайшет АТ-2	7
					Заводская АТ-1	10
					Заводская АТ-2	12
					БПП АТ-1	8
					БПП АТ-2	7
06.01.2020 14:00	0,0353446	-0,17633	22,2809	22,7794		
					ТЭЦ-11 АТ-1	6
					Н.Зиминская АТ-1	12
					Н.Зиминская АТ-2	11
					Тулун АТ-1	4
					Тайшет АТ-1	6
					Тайшет АТ-2	6
					БПП АТ-1	5
					БПП АТ-2	5
06.01.2020 14:30	0,0317739	-0,165228	22,3126	22,8111		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	6
					УП-15 АТ-2	6
					ТЭЦ-11 АТ-1	10
					ТЭЦ-11 АТ-2	11
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	5
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					Заводская АТ-1	15
					Заводская АТ-2	13
					БПП АТ-1	10
					БПП АТ-2	9
06.01.2020 15:00	0,0753808	-0,234169	22,388	22,8865		
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Тулун АТ-1	6
					БПП АТ-1	6
					БПП АТ-2	6
06.01.2020 18:30	0,191918	-0,399717	23,1534	23,6519		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
06.01.2020 19:00	0,145551	-0,309489	23,2989	23,7974		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
06.01.2020 18:30	0,191918	-0,399717	23,1534	23,8438		
					Шелехово АТ-8	7
					Ключи АТ-1	7

					Ключи АТ-2	7
					Ключи АТ-3	7
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
06.01.2020 19:00	0,145551	-0,309489	23,2989	23,9894		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
06.01.2020 19:30	0,229093	-0,429647	23,528	24,2185		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
06.01.2020 21:30	0,0444433	-0,0588744	24,1862	24,8767		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
07.01.2020 2:00	0,193594	-0,392242	25,42	26,1104		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
07.01.2020 2:30	0,0519491	-0,0622846	25,472	26,1624		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
07.01.2020 8:00	0,105421	-0,264374	26,6714	27,4672		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10

						Заводская АТ-1	15
						Заводская АТ-2	13
						Коршуниха АТ-1	6
						Коршуниха АТ-2	6
						УИГЭС АТ-1	7
						УИГЭС АТ-2	7
						БПП АТ-1	6
						БПП АТ-2	6
07.01.2020 14:00	0,0436145	-0,185799	27,7751	28,571			
						Ключи АТ-1	7
						Ключи АТ-2	7
						Ключи АТ-3	7
						УП-15 АТ-1	4
						УП-15 АТ-2	5
						ТЭЦ-11 АТ-1	10
						Н.Зиминская АТ-1	11
						Н.Зиминская АТ-2	11
						Тулун АТ-1	4
						Тайшет АТ-1	7
						Тайшет АТ-2	7
						Заводская АТ-1	16
						УИГЭС АТ-1	9
						УИГЭС АТ-2	9
						БПП АТ-1	12
						БПП АТ-2	12
07.01.2020 14:30	0,0599094	-0,216504	27,835	28,6309			
						Ключи АТ-1	6
						Ключи АТ-2	6
						Ключи АТ-3	6
						ТЭЦ-11 АТ-1	12
						ТЭЦ-11 АТ-2	11
						Н.Зиминская АТ-1	12
						Тулун АТ-1	1
						Тайшет АТ-1	3
						Тайшет АТ-2	3
						БПП АТ-1	10
						БПП АТ-2	10
07.01.2020 15:00	0,0618371	-0,212627	27,8969	28,6927			
						Ключи АТ-1	8
						Ключи АТ-2	8
						Ключи АТ-3	8
						УП-15 АТ-1	7
						УП-15 АТ-2	7
						ТЭЦ-11 АТ-1	6
						ТЭЦ-11 АТ-2	6
						Н.Зиминская АТ-1	7
						Н.Зиминская АТ-2	7
						Тулун АТ-1	6
						Тайшет АТ-1	9
						Тайшет АТ-2	9
						Заводская АТ-1	15
						УИГЭС АТ-1	7
						УИГЭС АТ-2	7
						БПП АТ-1	6
						БПП АТ-2	6
07.01.2020 15:30	0,0502361	-0,190477	27,9471	28,743			
						Ключи АТ-1	6
						Ключи АТ-2	6
						Ключи АТ-3	6
						УП-15 АТ-1	3
						УП-15 АТ-2	4

					ТЭЦ-11 АТ-1	15
					ТЭЦ-11 АТ-2	15
					Н.Зиминская АТ-1	2
					Н.Зиминская АТ-2	4
					Тулун АТ-1	5
					Тайшет АТ-1	8
					Тайшет АТ-2	8
					Заводская АТ-1	8
					Заводская АТ-2	12
					Коршуниха АТ-1	7
					Коршуниха АТ-2	7
					УИГЭС АТ-1	8
					УИГЭС АТ-2	8
					БПП АТ-1	13
					БПП АТ-2	13
07.01.2020 16:00	0,0516891	-0,191506	27,9988	28,7946		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
07.01.2020 16:30	0,128707	-0,334874	28,1275	28,9233		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
07.01.2020 17:30	0,138383	-0,326101	28,4129	29,2087		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
08.01.2020 5:00	0,0993554	-0,280386	29,0677	29,9629		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7

					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
08.01.2020 13:30	-0,340787	2,53762	30,2092	31,1044		
					БПП АТ-2	6
08.01.2020 14:00	0,0846612	-0,27069	30,2939	31,1891		
					БПП АТ-2	6
08.01.2020 19:30	-1,32659	10,1459	29,9219	30,8171		
					Шелехово АТ-8	10
					Ключи АТ-1	3
					Ключи АТ-2	3
					Ключи АТ-3	3
					УП-15 АТ-2	11
					ТЭЦ-11 АТ-1	10
					ТЭЦ-11 АТ-2	11
					Шелехово АТ-9	8
					Тулун АТ-1	13
					БЛПК АТ-1	10
					БЛПК АТ-2	10
					Заводская АТ-1	14
					УИГЭС АТ-1	8
					БПП АТ-1	7
					БПП АТ-2	8
09.01.2020 10:00	0,12083	-0,327099	30,5626	31,5786		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
09.01.2020 18:30	0,218135	-0,433672	32,5491	33,5651		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
09.01.2020 19:00	0,0152631	-0,0164213	32,5643	33,5804		
					Ключи АТ-1	8

					Ключи АТ-2	8
					Ключи АТ-3	8
11.01.2020 10:30	0,0389938	-0,178565	35,2388	36,2938		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
11.01.2020 11:30	0,0348736	-0,171077	35,3085	36,3635		
					Ключи АТ-1	4
					Ключи АТ-2	4
					Ключи АТ-3	4
					УП-15 АТ-1	2
					УП-15 АТ-2	4
					ТЭЦ-11 АТ-1	15
					ТЭЦ-11 АТ-2	15
					Н.Зиминская АТ-1	1
					Н.Зиминская АТ-2	5
					Тулун АТ-1	11
					Тайшет АТ-1	15
					Тайшет АТ-2	15
					БЛПК АТ-1	10
					БЛПК АТ-2	10
					Заводская АТ-1	21
					Заводская АТ-2	14
					УИГЭС АТ-1	9
					УИГЭС АТ-2	9
					БПП АТ-1	13
					БПП АТ-2	12
11.01.2020 12:00	0,0264168	-0,161834	35,3349	36,3899		
					УП-15 АТ-2	3
					ТЭЦ-11 АТ-1	14
					ТЭЦ-11 АТ-2	14
					Н.Зиминская АТ-1	2
					Н.Зиминская АТ-2	4
					Заводская АТ-1	22
					Заводская АТ-2	16
					БПП АТ-1	11
					БПП АТ-2	11
11.01.2020 12:30	0,0468329	-0,191074	35,3817	36,4367		
					Ключи АТ-1	8

					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Заводская АТ-1	15
					Заводская АТ-2	13
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
11.01.2020 13:30	0,0385993	-0,182096	35,4654	36,5204		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
					УП-15 АТ-1	6
					УП-15 АТ-2	6
					ТЭЦ-11 АТ-1	10
					ТЭЦ-11 АТ-2	10
					Н.Зиминская АТ-1	11
					Н.Зиминская АТ-2	10
					Тулун АТ-1	5
					Тайшет АТ-1	8
					Тайшет АТ-2	8
					Заводская АТ-1	17
					БПП АТ-2	5
11.01.2020 14:00	0,037245	-0,183178	35,5027	36,5577		
					Ключи АТ-1	6
					Ключи АТ-2	6
					Ключи АТ-3	6
					УП-15 АТ-1	7
					УП-15 АТ-2	10
					ТЭЦ-11 АТ-1	7
					ТЭЦ-11 АТ-2	7
					Тулун АТ-1	4
					БПП АТ-1	5
11.01.2020 14:30	0,0339431	-0,17722	35,5366	36,5916		
					Н.Зиминская АТ-1	10
					Тулун АТ-1	2
					Заводская АТ-1	16
					БПП АТ-1	6
11.01.2020 15:00	0,0279098	-0,165141	35,5645	36,6195		
					Ключи АТ-1	5
					Ключи АТ-2	5
					Ключи АТ-3	5
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	11
					Тулун АТ-1	4
					Заводская АТ-1	17
11.01.2020 15:30	0,0573515	-0,206358	35,6219	36,6769		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8

					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					Заводская АТ-1	15
					БПП АТ-2	6
11.01.2020 16:00	0,0447446	-0,184481	35,6666	36,7216		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
					УП-15 АТ-1	4
					УП-15 АТ-2	5
					ТЭЦ-11 АТ-1	12
					ТЭЦ-11 АТ-2	13
					Н.Зиминская АТ-1	4
					Н.Зиминская АТ-2	6
					Тулун АТ-1	7
					Тайшет АТ-1	12
					Тайшет АТ-2	12
					Заводская АТ-1	19
					Заводская АТ-2	14
					БПП АТ-1	10
					БПП АТ-2	9
11.01.2020 16:30	0,0479438	-0,191312	35,7146	36,7696		
					Ключи АТ-1	6
					Ключи АТ-2	6
					Ключи АТ-3	6
					УП-15 АТ-1	1
					УП-15 АТ-2	1
					ТЭЦ-11 АТ-1	15
					ТЭЦ-11 АТ-2	15
					Тайшет АТ-1	11
					Тайшет АТ-2	11
					БЛПК АТ-1	10
					БЛПК АТ-2	10
					Заводская АТ-1	20
					УИГЭС АТ-1	6
					УИГЭС АТ-2	6
					БПП АТ-2	8
11.01.2020 17:00	0,0446794	-0,186533	35,7592	36,8142		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
					УП-15 АТ-1	5
					УП-15 АТ-2	5
					ТЭЦ-11 АТ-1	11
					ТЭЦ-11 АТ-2	13
					Н.Зиминская АТ-1	6
					Н.Зиминская АТ-2	7
					Тайшет АТ-1	10
					Тайшет АТ-2	10
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Заводская АТ-1	18
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	9
11.01.2020 17:30	0,0406597	-0,173024	35,7999	36,8549		

					ТЭЦ-11 АТ-2	12
					Тулун АТ-1	10
					Тайшет АТ-1	12
					Тайшет АТ-2	12
					УИГЭС АТ-1	6
					УИГЭС АТ-2	6
					БПП АТ-2	9
11.01.2020 18:00	0,0469582	-0,187837	35,8468	36,9019		
					УП-15 АТ-1	4
					ТЭЦ-11 АТ-1	12
					ТЭЦ-11 АТ-2	13
					БПП АТ-1	10
11.01.2020 18:30	0,0445314	-0,180201	35,8914	36,9464		
					УП-15 АТ-1	5
					ТЭЦ-11 АТ-1	11
					Н.Зиминская АТ-1	5
					Н.Зиминская АТ-2	6
					Тайшет АТ-1	11
					Тайшет АТ-2	11
					Заводская АТ-1	16
					Заводская АТ-2	13
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	9
11.01.2020 19:00	0,251153	-0,569401	36,1425	37,1975		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					Заводская АТ-1	15
					БПП АТ-1	6
					БПП АТ-2	6
11.01.2020 19:30	0,185439	-0,34497	36,328	37,383		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
12.01.2020 11:30	0,048607	-0,195558	38,1761	39,2797		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7

					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
12.01.2020 12:30	0,0470587	-0,186624	38,2834	39,387		
					УП-15 АТ-1	5
					УП-15 АТ-2	6
					ТЭЦ-11 АТ-1	11
					ТЭЦ-11 АТ-2	13
					Н.Зиминская АТ-1	5
					Н.Зиминская АТ-2	6
					Тайшет АТ-1	11
					Тайшет АТ-2	11
					Заводская АТ-1	16
					БПП АТ-1	10
					БПП АТ-2	9
12.01.2020 13:00	0,0553106	-0,203716	38,3387	39,4423		
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					Заводская АТ-1	15
					БПП АТ-1	6
					БПП АТ-2	6
12.01.2020 15:30	0,0361783	-0,179938	38,5852	39,6888		
					Ключи АТ-1	6
					Ключи АТ-2	6
					Ключи АТ-3	6
					УП-15 АТ-1	3
					УП-15 АТ-2	3
					ТЭЦ-11 АТ-1	13
					ТЭЦ-11 АТ-2	12
					Н.Зиминская АТ-1	3
					Н.Зиминская АТ-2	5
					Тулун АТ-1	4
					Тайшет АТ-1	8
					Тайшет АТ-2	8
					БЛПК АТ-1	10
					БЛПК АТ-2	10
					Заводская АТ-1	19
					Заводская АТ-2	14
					УИГЭС АТ-1	9
					УИГЭС АТ-2	9
					БПП АТ-1	9
					БПП АТ-2	10
12.01.2020 16:00	0,0438477	-0,189093	38,629	39,7326		
					УП-15 АТ-1	2
					ТЭЦ-11 АТ-1	14
					ТЭЦ-11 АТ-2	14
					Н.Зиминская АТ-1	5
					Н.Зиминская АТ-2	7
					Тулун АТ-1	5

						Тайшет АТ-1	6
						Тайшет АТ-2	6
						Заводская АТ-1	11
						Заводская АТ-2	12
						УИГЭС АТ-1	8
						УИГЭС АТ-2	8
						БПП АТ-1	11
						БПП АТ-2	12
12.01.2020 16:30	0,0359948	-0,179454	38,665	39,7686			
						УП-15 АТ-1	3
						УП-15 АТ-2	2
						ТЭЦ-11 АТ-1	13
						ТЭЦ-11 АТ-2	13
						Н.Зиминская АТ-1	2
						Н.Зиминская АТ-2	5
						Тулун АТ-1	4
						Тайшет АТ-1	7
						Заводская АТ-1	18
						Заводская АТ-2	14
						БПП АТ-1	10
						БПП АТ-2	9
12.01.2020 17:00	0,0431766	-0,188635	38,7082	39,8118			
						УП-15 АТ-1	6
						УП-15 АТ-2	6
						Н.Зиминская АТ-1	4
						Н.Зиминская АТ-2	6
						Тулун АТ-1	13
						Тайшет АТ-1	10
						Тайшет АТ-2	11
						Заводская АТ-1	16
						Заводская АТ-2	13
						УИГЭС АТ-1	9
						УИГЭС АТ-2	9
						БПП АТ-2	10
12.01.2020 17:30	0,0415966	-0,185633	38,7498	39,8534			
						Ключи АТ-1	8
						Ключи АТ-2	8
						Ключи АТ-3	8
						УП-15 АТ-1	7
						УП-15 АТ-2	7
						ТЭЦ-11 АТ-1	6
						ТЭЦ-11 АТ-2	6
						Н.Зиминская АТ-1	7
						Н.Зиминская АТ-2	7
						Тулун АТ-1	6
						Тайшет АТ-1	9
						Тайшет АТ-2	9
						БЛПК АТ-1	7
						БЛПК АТ-2	7
						Заводская АТ-1	15
						УИГЭС АТ-1	7
						УИГЭС АТ-2	7
						БПП АТ-1	6
						БПП АТ-2	6
12.01.2020 18:00	0,0331389	-0,0340005	38,7829	39,8865			
						Ключи АТ-1	6
						Ключи АТ-2	6
						Ключи АТ-3	6
						УП-15 АТ-2	6
						ТЭЦ-11 АТ-1	7
						Н.Зиминская АТ-1	4

						Н.Зиминская АТ-2	4
						Тулун АТ-1	14
						Тайшет АТ-1	14
						Тайшет АТ-2	13
						УИГЭС АТ-1	8
						УИГЭС АТ-2	8
						БПП АТ-1	5
						БПП АТ-2	7
12.01.2020 18:30	0,0439671	-0,180545	38,8269	39,9305			
						Ключи АТ-1	8
						Ключи АТ-2	8
						Ключи АТ-3	8
						УП-15 АТ-1	5
						ТЭЦ-11 АТ-1	10
						ТЭЦ-11 АТ-2	11
						Н.Зиминская АТ-2	6
						Тулун АТ-1	7
						Тайшет АТ-1	10
						Тайшет АТ-2	10
						Заводская АТ-1	16
						УИГЭС АТ-1	7
						УИГЭС АТ-2	7
						БПП АТ-1	10
						БПП АТ-2	10
12.01.2020 19:00	0,0343185	-0,172671	38,8612	39,9648			
						УП-15 АТ-1	7
						УП-15 АТ-2	7
						ТЭЦ-11 АТ-1	6
						ТЭЦ-11 АТ-2	6
						Н.Зиминская АТ-1	7
						Н.Зиминская АТ-2	7
						Тулун АТ-1	6
						Тайшет АТ-1	9
						Тайшет АТ-2	9
						Заводская АТ-1	15
						БПП АТ-1	6
						БПП АТ-2	6
12.01.2020 20:00	0,196741	-0,394482	39,0964	40,2			
						Ключи АТ-1	8
						Ключи АТ-2	8
						Ключи АТ-3	8
12.01.2020 21:00	-0,830159	1,99214	38,4762	39,5798			
						Ключи АТ-1	2
						Ключи АТ-2	2
						Ключи АТ-3	2
						УП-15 АТ-2	11
						ТЭЦ-11 АТ-1	11
						ТЭЦ-11 АТ-2	12
						Шелехово АТ-9	8
						Н.Зиминская АТ-1	10
						Н.Зиминская АТ-2	10
						Тулун АТ-1	13
						Тайшет АТ-1	8
						Тайшет АТ-2	8
						БЛПК АТ-1	10
						БЛПК АТ-2	10
						Заводская АТ-1	14
						БПП АТ-2	7
13.01.2020 17:00	0,0248628	-0,159217	40,5996	41,728			
						Шелехово АТ-8	7
						Ключи АТ-1	8

						Ключи АТ-2	8
						Ключи АТ-3	8
						УП-15 АТ-1	7
						УП-15 АТ-2	7
						ТЭЦ-11 АТ-1	6
						ТЭЦ-11 АТ-2	6
						Шелехово АТ-9	9
						Н.Зиминская АТ-1	7
						Н.Зиминская АТ-2	7
						Тулун АТ-1	6
						Тайшет АТ-1	9
						Тайшет АТ-2	9
						БЛПК АТ-1	7
						БЛПК АТ-2	7
						Падунская Т-3	10
						Заводская АТ-1	15
						Заводская АТ-2	13
						Коршуниха АТ-1	6
						Коршуниха АТ-2	6
						УИГЭС АТ-1	7
						УИГЭС АТ-2	7
						БПП АТ-1	6
						БПП АТ-2	6
13.01.2020 18:00	0,0327079	-0,169199	40,6641	41,7926			
						Ключи АТ-1	7
						Ключи АТ-2	7
						Ключи АТ-3	7
						УП-15 АТ-1	3
						УП-15 АТ-2	5
						ТЭЦ-11 АТ-1	13
						ТЭЦ-11 АТ-2	7
						Н.Зиминская АТ-1	4
						Н.Зиминская АТ-2	6
						Тулун АТ-1	10
						Тайшет АТ-1	12
						Тайшет АТ-2	12
						Заводская АТ-1	21
						Заводская АТ-2	14
						УИГЭС АТ-1	8
						БПП АТ-1	10
						БПП АТ-2	10
13.01.2020 18:30	0,0377093	-0,173166	40,7019	41,8303			
						Ключи АТ-1	8
						Ключи АТ-2	8
						Ключи АТ-3	8
						УП-15 АТ-1	7
						УП-15 АТ-2	7
						ТЭЦ-11 АТ-1	6
						ТЭЦ-11 АТ-2	6
						Н.Зиминская АТ-1	7
						Н.Зиминская АТ-2	7
						Тулун АТ-1	6
						Тайшет АТ-1	9
						Тайшет АТ-2	9
						Заводская АТ-1	15
						Заводская АТ-2	13
						УИГЭС АТ-1	7
						БПП АТ-1	6
						БПП АТ-2	6
14.01.2020 1:30	-1,17687	0,279708	40,49	41,6185			
						Ключи АТ-1	8

					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Заводская АТ-1	15
					БПП АТ-1	6
					БПП АТ-2	6
14.01.2020 2:00	0,0793722	-0,235046	40,5694	41,6979		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Заводская АТ-1	15
					БПП АТ-1	6
					БПП АТ-2	6
14.01.2020 18:30	0,233331	-0,46927	41,7777	42,9062		
					Ключи АТ-1	6
					Ключи АТ-2	6
					Ключи АТ-3	6
					УП-15 АТ-2	10
					ТЭЦ-11 АТ-1	7
					ТЭЦ-11 АТ-2	7
					Тулун АТ-1	7
15.01.2020 19:30	0,105294	-0,260204	43,7651	44,8936		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Тулун АТ-1	6
15.01.2020 20:00	0,0679414	-0,211687	43,8331	44,9615		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Тулун АТ-1	6
24.01.2020 20:00	0,00611445	-0,463701	52,5989	53,7274		
					Ключи АТ-1	7
					Ключи АТ-2	7
					Ключи АТ-3	7
28.01.2020 18:30	0,159916	-0,355294	59,6631	60,7916		

					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
28.01.2020 19:00	0,103158	-0,259024	59,7663	60,8947		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
29.01.2020 16:00	0,000419887	-0,000398925	61,5236	62,6525		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Падунская Т-3	10
					Заводская АТ-1	15
					Заводская АТ-2	13
					Коршуниха АТ-1	6
					Коршуниха АТ-2	6
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
29.01.2020 17:30	0,0449994	-0,179274	61,6593	62,7882		
					Шелехово АТ-8	10
					Ключи АТ-1	6
					Ключи АТ-2	6
					Ключи АТ-3	6
					УП-15 АТ-1	1
					УП-15 АТ-2	1
					ТЭЦ-11 АТ-1	15
					ТЭЦ-11 АТ-2	15
					Шелехово АТ-9	8
					Н.Зиминская АТ-1	1
					Н.Зиминская АТ-2	2
					Тулун АТ-1	12
					Тайшет АТ-1	14
					Тайшет АТ-2	14
					БЛПК АТ-1	10
					БЛПК АТ-2	10
					Заводская АТ-1	10
					Заводская АТ-2	12
					УИГЭС АТ-1	10
					УИГЭС АТ-2	10
					БПП АТ-1	13
					БПП АТ-2	13
29.01.2020 18:00	0,0412328	-0,178166	61,7005	62,8294		
					Шелехово АТ-8	7
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8

					УП-15 АТ-1	7
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
					Шелехово АТ-9	9
					Н.Зиминская АТ-1	7
					Н.Зиминская АТ-2	7
					Тулун АТ-1	6
					Тайшет АТ-1	9
					Тайшет АТ-2	9
					БЛПК АТ-1	7
					БЛПК АТ-2	7
					Заводская АТ-1	15
					Заводская АТ-2	13
					УИГЭС АТ-1	7
					УИГЭС АТ-2	7
					БПП АТ-1	6
					БПП АТ-2	6
30.01.2020 0:30	0,0577779	-0,389908	62,369	63,4979		
					Ключи АТ-1	8
					Ключи АТ-2	8
					Ключи АТ-3	8
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6
30.01.2020 1:00	0,0544677	-0,438523	62,4235	63,5524		
					УП-15 АТ-2	7
					ТЭЦ-11 АТ-1	6
					ТЭЦ-11 АТ-2	6

ПРИЛОЖЕНИЕ 3

Описание программной платформы АНАРЭС

ПВК АНАРЭС в версии 2020 г. решает следующие задачи:

- расчет установившегося режима;
- оптимизация потерь и ввод в допустимую область по напряжениям;
- оценивание состояния;
- расчет предельных режимов методом утяжеления (статическая устойчивость, предельно допустимые режимы по токам, напряжениям, перетокам);
- расчет электромеханических переходных процессов;
- расчет токов коротких замыканий;
- анализ режимной надежности (с моделированием устройств противоаварийной автоматики и релейной защиты);
- подготовка и работа с мнемосхемами (структурные схемы, схемы электрических соединений).

Программный комплекс имеет эргономичный пользовательский интерфейс, разработанный под непосредственным руководством автора и с его участием. Данный интерфейс прошел опробование в службе режимов ЦУС сетевой компании в тесном взаимодействии с пользователями.

№	Название	U ном	U нач	U расч	Угол U нач	Угол U	Rн ном	Rн оцен	Rн расч	Qн ном	Qн оцен	Qн расч	Rген ном	Rген с
108	АТ-8 НН ПС 500 кВ Иркутская	10.50	0.00	10.01	0.00	-0.11	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
109	АТ-9 НН ПС 500 кВ Иркутская	10.50	0.00	10.55	0.00	-0.12	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
110	АТ-10 НН ПС 500 кВ Иркутская	10.50	0.00	10.48	0.00	-0.12	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
400	ГГ-7-8 Братская ГЭС	15.00	0.00	15.07	0.00	-0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
401	ГГ-5-6 Братская ГЭС	15.00	0.00	15.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
402	ГГ-3-4 Братская ГЭС	15.00	0.00	14.50	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
403	ГГ-1-2 Братская ГЭС	15.00	0.00	14.66	0.00	-0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
404	2АТ НН Братская ГЭС	10.50	0.00	10.40	0.00	-0.04	0.00	2.00	2.00	0.00	1.10	1.10	0.00	0.00
405	1АТ НН Братская ГЭС	10.50	0.00	10.57	0.00	-0.03	0.00	2.00	2.00	0.00	1.10	1.10	0.00	0.00
600	ГТГ-6 Усть-Илимская ГЭС	15.00	0.00	15.91	0.00	0.25	0.00	0.00	0.00	0.00	-67.80	-67.80	0.00	0.00
601	ГТГ-8 Усть-Илимская ГЭС	15.00	0.00	15.71	0.00	0.29	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
602	ГТГ-10 Усть-Илимская ГЭС	15.00	0.00	15.65	0.00	0.25	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
603	ГТГ-11-12 Усть-Илимская ГЭС	15.00	0.00	15.65	0.00	0.25	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
604	ГТГ-13-14 Усть-Илимская ГЭС	15.00	0.00	15.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
605	ГТГ-15-16 Усть-Илимская ГЭС	15.00	0.00	15.64	0.00	0.25	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
606	1АТ НН Усть-Илимская ГЭС	35.00	0.00	39.48	0.00	0.22	0.00	1.00	1.00	0.00	0.60	0.60	0.00	0.00
607	2АТ НН Усть-Илимская ГЭС	35.00	0.00	39.51	0.00	0.22	0.00	0.60	0.60	0.00	0.40	0.40	0.00	0.00
700	АТ-2 НН Братский ПП	10.50	0.00	11.25	0.00	-0.01	0.00	0.50	0.50	0.00	0.30	0.30	0.00	0.00
701	АТ-1 НН Братский ПП	10.50	0.00	11.26	0.00	-0.01	0.00	0.50	0.50	0.00	0.30	0.30	0.00	0.00
800	2 АТ-500 НН ПС 500 кВ Тайшет	35.00	0.00	39.98	0.00	-0.03	0.00	3.40	3.40	0.00	2.70	2.70	0.00	0.00
801	1 АТ-500 НН ПС 500 кВ Тайшет	35.00	0.00	39.92	0.00	-0.04	0.00	11.70	11.70	0.00	4.70	4.70	0.00	0.00
1400	1, 2 СШ-110 ПС 500 кВ Тайшет	110.00	0.00	125.63	0.00	-0.02	0.00	158.70	158.70	0.00	36.40	36.40	0.00	0.00
4	АТ-1 (200 кВ) ПС Кудинск	200.00	0.00	200.18	0.00	0.14	0.00	00.00	00.00	0.00	21.00	21.00	0.00	0.00

Сообщения в таблицах

- ⚠️ Одинаковые пределы по Qген в узле. Qген фиксируется
- ⚠️ Нулевые пределы по Rген в узле. Rген опускается.
- ⚠️ Для Подсхемы 1 назначен балансирующий по Q узел:5400

Рис. П.3.1 – Табличное представление данных.

Весь комплекс построен на едином интерфейсе, примеры которого представлены на скриншотах (Рис. П.3.1 - Рис. П.3.5). Разработанный интерфейс позволяет

гибко настраивать отображение данных в таблицах под требования пользователя. Имеются такие возможности, как:

- создание фильтров;
- создание пользовательских таблиц;
- подсветка ячеек по условию;
- и другие функции свойственные современным табличным редакторам.

№ узла	№ экв	Название	Цном	Цизм	Урасч	Угол U	DU	OO U	Rн изм	Rн расч	DPн	OO P	Qн изм	Qн расч	DQн	OO Q	Rген изм	Rген расч	DRген			
108	108	АТ-8 НН ПС 500 кВ Иркутская	x	10.5		0.00	0.00	0.0								0.0						
109	109	АТ-9 НН ПС 500 кВ Иркутская		10.5		10.64	-12.63	0.0								-1.5						
110	110	АТ-10 НН ПС 500 кВ Иркутская		10.5		10.65	-12.69	0.0								-1.5						
400	400	ГГ-7-8 Братская ГЭС	x	15.0		0.00	0.00	0.0								0.0	T	0.0	0.0	0.1		
401	401	ГГ-5-6 Братская ГЭС		15.0		15.17	5.32	0.0								0.0	T	441.5	441.5	0.1		
402	402	ГГ-3-4 Братская ГЭС		15.0		15.29	3.01	0.0								-0.1	T	218.7	218.7	0.1		
403	403	ГГ-1-2 Братская ГЭС		15.0		15.07	3.11	0.0								-0.1	T	220.5	220.5	0.1		
404	404	2АТ НН Братская ГЭС		10.5		10.38	-3.12	0.0	S	1.8	1.6	0.6	-0.3	S	1.2	1.0	0.3	-0.8				
405	405	1АТ НН Братская ГЭС		10.5		10.53	-2.04	0.0	S	1.8	1.7	0.6	-0.2	S	1.2	1.0	0.3	-0.7				
600	600	ГТ5-6 Усть-Илимская ГЭС	x	15.0		0.00	0.00	0.0	B	0.0	0.0	0.1	0.0	B	0.0	0.0	0.1	0.0	T	0.0	0.0	0.1
601	601	ГТ7-8 Усть-Илимская ГЭС		15.0		15.66	18.24	0.0								0.7						
602	602	ГТ9-10 Усть-Илимская ГЭС		15.0		15.63	15.44	0.0								0.4						
603	603	ГТ11-12 Усть-Илимская ГЭС		15.0		15.64	15.47	0.0								0.4						
604	604	ГТ13-14 Усть-Илимская ГЭС		15.0		15.65	15.47	0.0								0.4						
605	605	ГТ15-16 Усть-Илимская ГЭС		15.0		15.68	18.18	0.0								0.7						
606	606	1АТ НН Усть-Илимская ГЭС		35.0		40.20	13.45	0.0	S	1.3	1.4	0.4	0.2	S	0.9	0.0	0.3	-3.1				
607	607	2АТ НН Усть-Илимская ГЭС		35.0		40.24	13.49	0.0	S	0.3	0.3	0.1	0.2	S	0.2	-0.1	0.1	-3.1				
700	700	АТ-2 НН Братской ПП		10.5		11.15	-3.05	0.0	S	0.4	0.4	0.1	-0.4	S	0.3	0.3	0.1	-0.4				
701	701	АТ-1 НН Братской ПП		10.5		11.15	-3.04	0.0	S	0.4	0.4	0.1	-0.3	S	0.3	0.3	0.1	-0.4				
800	800	2 АТ-500 НН ПС 500 кВ Тайшет		35.0		38.97	-12.21	0.0	T	23.3	21.6	2.0	-0.9	T	7.3	4.9	1.0	-2.4				
801	801	1 АТ-500 НН ПС 500 кВ Тайшет		35.0	T	36.8	39.13	-11.25	1.0	2.4	T	0.0	-1.6	2.0	-0.8	T	0.0	-0.1	1.0	-0.1		
1400	1400	1, 2 СШ-110 ПС 500 кВ Тайшет		110.0		122.71	-11.03	0.0	V	222.9	215.1	10.0	-0.8	V	61.3	38.1	10.0	-2.3				
2015	2015	АТ-1 (220 кВ) ПС Ключи		220.0		227.05	-13.79	2.0	T	142.2	138.9	5.0	-0.7	T	26.7	22.4	5.0	-0.9				
2016	2016	АТ-2 (220 кВ) ПС Ключи		220.0		229.29	-13.75	0.0	T	140.0	136.7	5.0	-0.7	T	27.3	23.0	5.0	-0.9				
2017	2017	АТ-3 (220 кВ) ПС Ключи	x	220.0		0.00	0.00	0.0	T	0.0	0.0	0.0	2.0	T	0.3	0.0	2.0	0.0				
2100	2100	1, 2 СШ 220 ПС 500 кВ Иркутская	x	220.0		0.00	0.00	0.0	T	0.0	0.0	5.0	0.0	T	0.0	0.0	5.0	0.0				
2110	2110	3, 4 СШ 220 ПС 500 кВ Иркутская		220.0		234.26	-12.59	0.0	T	89.2	81.5	5.0	-1.5	T	109.5	106.5	5.0	-0.6				
2120	2120	5, 6 СШ 220 ПС 500 кВ Иркутская		220.0		234.45	-12.64	0.0	T	96.4	88.7	5.0	-1.5	T	104.5	101.5	5.0	-0.6				

Рис. П.3.2 – Табличное представление данных (одновременно может быть открыто любое количество вкладок).

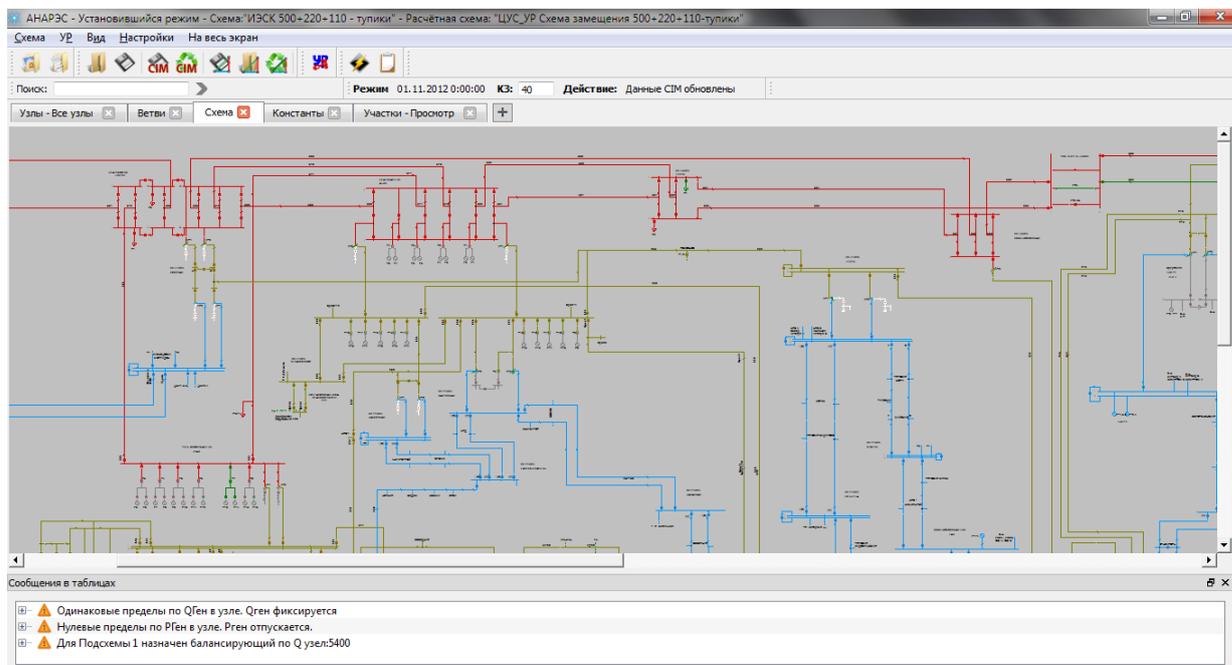


Рис. П.3.3 – Отображение графических схем.

Имеется механизм, позволяющий переходить из любого элемента оборудования (объекта) на связанные объекты. Например, из объекта «Нагрузка» на элемент схемы, представляющий данную нагрузку.

Интерфейс работы со схемами встраивается в любое приложение комплекса. Комплекс позволяет работать со схемами любой сложности и размерности (структурные схемы, подробные диспетчерские схемы, эквивалентные схемы).

Система отображения на схемах имеет такие функции, как:

- отображение на схемах результатов расчета и исходных данных;
- взаимодействие с объектной моделью ЭЭС;
- выполнение изменения исходных данных, как непосредственно со схемы, так и переход в таблицы;
- интерактивное выполнение коммутаций в модели электрической сети со схемы;
- динамическая раскраска схемы по определенному параметру, или результату работы функций анализа топологии (например, отображение связанности).

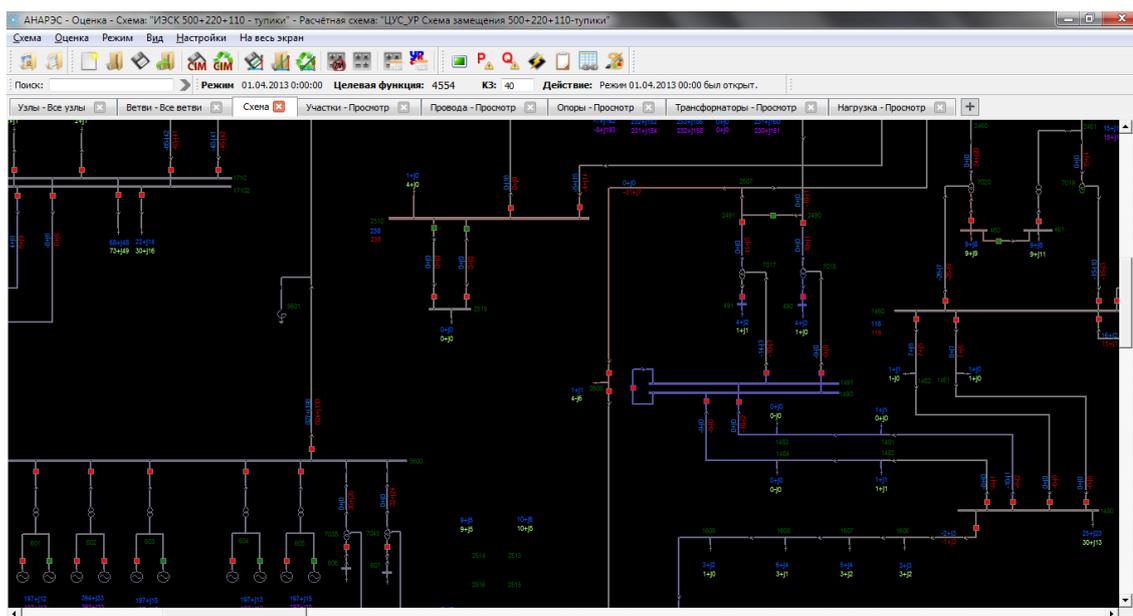


Рис. П.3.4 – Динамическая раскраска по уровню относительного отклонения в задаче оценивания состояния.

Комплекс адаптирован для работы в много-мониторной системе. Можно расположить вкладку со схемой на одном мониторе, а вкладки с таблицами на другом. При этом удобно использовать навигацию переходов между представлением объектов на схеме и в таблицах (и между таблицами).

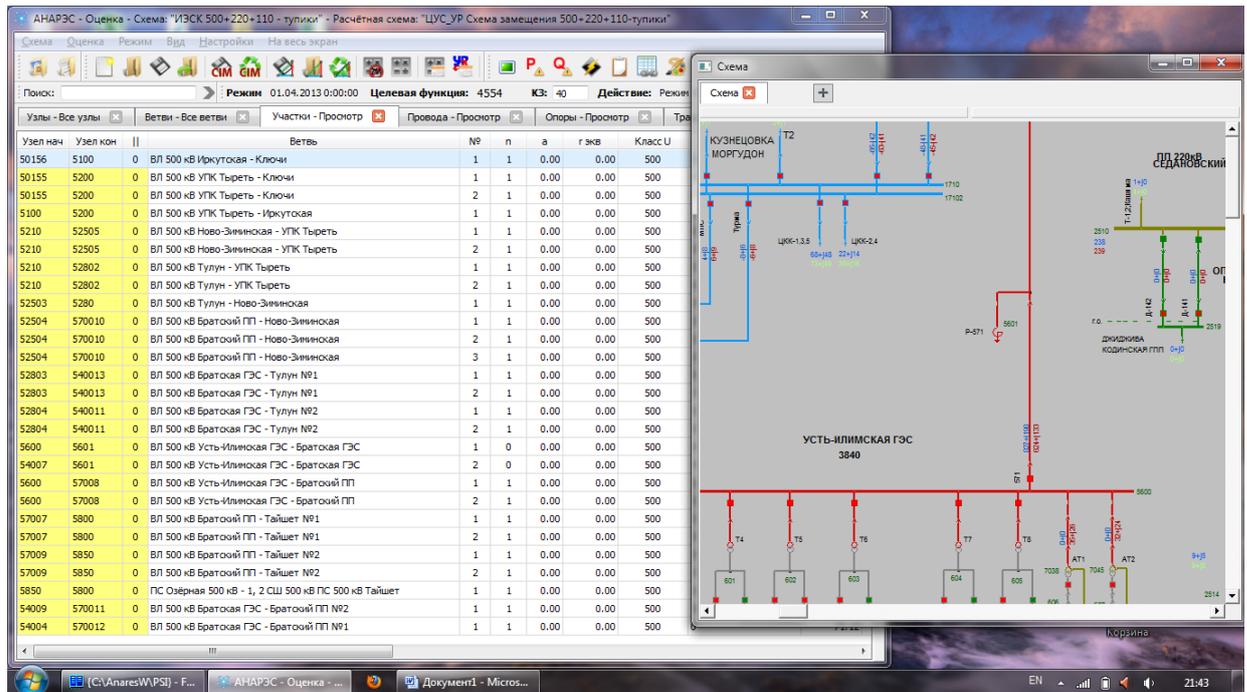


Рис. П.3.5 – Работа на много-мониторной системе.

ПРИЛОЖЕНИЕ 4



ОБЩЕСТВО С ОГРАНИЧЕННОЙ
ОТВЕТСТВЕННОСТЬЮ
«Энергия-Т»

Громовой ул., д.60, Тольятти, 445045
Самарская обл., Россия
тел: (8482) 24-53-21, факс: 25-63-22
<http://www.energy-t.ru>
e-mail: info@energy-t.ru

12.11.2020 № 252

на № _____ от _____

УТВЕРЖДАЮ
Генеральный директор
ООО "Энергия-Т"

А.В.Карманов



А К Т

о внедрении результатов
диссертационной работы
Домышева Александра Владимировича

Настоящим актом подтверждаем, что результаты диссертационной работы Домышева Александра Владимировича «Оптимизация нормальных электрических режимов электроэнергетических систем при оперативном и автоматическом управлении», представленной на соискание ученой степени кандидата технических наук, а именно «Подсистема оптимального управления напряжением и реактивной мощностью энергосистемы/энергорайона» внедрены в состав программно-технического комплекса интеллектуального управления напряжением и реактивной мощностью (ПТК ИУНРМ). ПТК ИУНРМ предназначен для оптимального управления электрическими режимами в ПАО «Магаданэнерго».

Главный конструктор
ООО «Энергия-Т»

К.В. Замула

Инженер-конструктор
ООО «Энергия-Т»

Е.А. Володин

ПРИЛОЖЕНИЕ 5



“Утверждаю”
Проректор по учебной работе
ФГБОУ ВО ИРНИТУ

к.х.н., доцент Смирнов В.В.

“ ” 2020г.

Акт

о внедрении результатов диссертационной работы
Домышева Александра Владимировича
в учебный процесс Иркутского национального исследовательского
технического университета

Настоящий акт подтверждает, что результаты диссертационной работы Домышева Александра Владимировича «Оптимизация нормальных электрических режимов электроэнергетических систем при оперативном и автоматическом управлении», представленной на соискание ученой степени кандидата технических наук, а именно: «Программное обеспечение автоматического оптимального управления нормальными режимами» совместно с цифровым двойником энергосистемы, разработанном на основе ПВК АНАРЭС, внедрены в учебный процесс института энергетики ФГБОУ ВО «Иркутский национальный исследовательский технический университет». Полученные в диссертационной работе материалы используются при подготовке магистров по направлению 13.04.02 “Электроэнергетика и электротехника” при проведении занятий по дисциплинам: “Интеграция установок на базе нетрадиционных и возобновляемых источников энергии в энергосистему”, “Принципы управления энергопотреблением”, “Интеллектуальные системы энергетики”, “Распределенная генерация в системах электроснабжения”.

Методическая и экспериментальная работа позволили повысить уровень выпускников кафедры и усовершенствовать исследовательскую часть при выполнении лабораторных работ.

Полученные в диссертационной работе Домышева А.В. также используются при выполнении курсового проектирования и подготовке выпускных квалификационных работ магистрантов.

Директор института энергетики
к.т.н., доцент

В.В.Федчишин

ПРИЛОЖЕНИЕ 6

Свидетельство о государственной регистрации программы для ЭВМ «Блок динамической оптимизации ПВК АНАРЭС»

РОССИЙСКАЯ ФЕДЕРАЦИЯ

RU

2020618440

ФЕДЕРАЛЬНАЯ СЛУЖБА
ПО ИНТЕЛЛЕКТУАЛЬНОЙ СОБСТВЕННОСТИ
(12) ГОСУДАРСТВЕННАЯ РЕГИСТРАЦИЯ ПРОГРАММЫ ДЛЯ ЭВМ

Номер регистрации (свидетельства):

2020618440

Дата регистрации: **29.07.2020**

Номер и дата поступления заявки:

2020614997 21.05.2020

Дата публикации: 29.07.2020

Контактные реквизиты:

+79148823938,
domyshev@isem.irk.ru

Автор:

Домышев Александр Владимирович (RU)

Правообладатель:

Федеральное государственное бюджетное
учреждение науки Институт систем энергетики им.
Л.А. Мелентьева Сибирского отделения
Российской академии наук (RU)

Название программы для ЭВМ:

Программа динамической оптимизации для ПВК «АНАРЭС»

Реферат:

Программа обеспечивает ввод электрического режима электроэнергетической системы в допустимую область и его многокритериальную оптимизацию на выбранный диапазон времени. Области применения: в службах электрических режимов электроэнергетических систем, электрических сетей и промышленных предприятий. Функциональные возможности: ввод режима в допустимую область и многокритериальная оптимизация; учет множественных ограничений на параметры электрического режима; прогнозирование режимов на основе графиков нагрузок. ОС: Windows версии 7 и выше, Linux.

Язык программирования: C++

Объем программы для ЭВМ: 12 Мб