

На правах рукописи



ПАЛЬЧЕВСКИЙ Евгений Владимирович

МЕТОДЫ НЕЙРОСЕТЕВОЙ ОБРАБОТКИ БОЛЬШИХ  
ТЕМПОРАЛЬНЫХ ДАННЫХ ДЛЯ ИНФОРМАЦИОННОЙ  
ПОДДЕРЖКИ ПРИНЯТИЯ УПРАВЛЕНЧЕСКИХ РЕШЕНИЙ  
(НА ПРИМЕРЕ ЭЛЕКТРОЭНЕРГЕТИКИ)

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

АВТОРЕФРЕРАТ  
диссертации на соискание ученой степени кандидата технических наук

Уфа – 2024

Работа выполнена в Федеральном государственном бюджетном образовательном учреждении высшего образования «Уфимский университет науки и технологий (УУНиТ)».

Научный руководитель: доктор технических наук, доцент  
**Антонов Вячеслав Викторович**

Официальные оппоненты:

**Филимонов Николай Борисович**, доктор технических наук, старший научный сотрудник, ФГБОУ ВО «Московский государственный университет имени М.В. Ломоносова», профессор, заместитель заведующего кафедрой физико-математических методов управления

**Затонский Андрей Владимирович**, доктор технических наук, профессор, ФГБОУ ВО «Пермский национальный исследовательский политехнический университет», Березниковский филиал, заведующий кафедрой автоматизации технологических процессов

Ведущая организация: ФГБОУ ВО «Удмуртский государственный университет», г. Ижевск

Защита диссертации состоится 26.06.2024 в 10<sup>00</sup> часов на заседании диссертационного совета 24.2.479.02, созданного на базе ФГБОУ ВО «Уфимский университет науки и технологий», по адресу: 450008, Республика Башкортостан, г. Уфа, ул. Карла Маркса, д.12.

Автореферат разослан «\_\_» \_\_\_\_\_ 2024 г.

Ученый секретарь

Диссертационного совета



О.Н. Сметанина

## ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

**Актуальность темы исследования.** В концепции «Цифровая трансформация 2030», определяющей национальные цели и стратегические задачи развития Российской Федерации на период до 2030 года, указаны специализированные цели и задачи, являющиеся важным посылом для внедрения интеллектуальных информационных технологий управления и обработки больших данных во все сферы экономики Российской Федерации. Согласно программе «Развитие энергетики» до 2035 года и доктрине «Энергетическая безопасность Российской Федерации» является необходимым развитие цифровых интеллектуальных технологий для внедрения их в области энергетики, в том числе и в электроэнергетике. При этом основными вызовами для перехода к цифровой трансформации и цифровым интеллектуальным технологиям при обработке больших данных является повышение скорости генерации информации и увеличение объема данных. Из-за огромного объема и присущей этим данным темпоральности и разнородности, классические методы обработки данных не подходят для работы с ними. Как следствие, спрос на более быструю обработку больших данных ежедневно растет, и многие исследователи сосредоточились на модификации методов их обработки, сделав упор на точность при решении задач классификации, кластеризации и регрессии. Более того, при принятии управленческих и коммерческих решений в организациях планирование и контроль имеют решающее значение. Прогнозирование является фундаментом планирования и контроля, в связи с чем попытки рассчитать и предсказать будущие тенденции необходимы для функционирования различных секторов экономики Российской Федерации, в том числе и в электроэнергетике. При этом руководство энергетических предприятий использует информацию, полученную в результате прогнозирования, для принятия важных решений.

Таким образом, появилась задача прогнозирования значений потребления электроэнергии для предприятий энергетической отрасли. Для этого необходимо разработать прототип системы поддержки принятия решений (СППР) путем объединения в единый процесс следующих подпроцессов: обработка первичного потока данных со счетчиков, датчиков и метеорологических ресурсов и формирования исходного датасета путем получения правил обработки (фильтрации) сетевого потока данных (СПД); автоматическое определение необходимости переобучения искусственных нейронных сетей (ИНС); прогнозирование значений потребления электроэнергии.

В связи с этим **актуальность** диссертационного исследования обусловлена необходимостью разработки методов обработки больших темпоральных данных и прогнозирования временных рядов с целью повышения эффективности информационной поддержки принятия управленческих решений.

**Степень разработанности темы.** Задачам обработки больших данных, в том числе и прогнозированию временных рядов (ВР) в самых различных областях посвящено большое количество исследований как российских, так и зарубежных ученых, в которых широко обсуждаются проблемы повышения точности расчета прогнозных значений при большом прогнозном горизонте и вопросы обработки больших объемов информации, в том числе и с использованием нейросетевых технологий:

– задачами обработки больших данных занимались Бартоломей П.И., Васильев В.И., Вульфин А.М., Гриценко Е.М., Зегжда Д.П., Тагирова К.Ф., Четырбок П.В., Devi B.S., Peng T. и др. В особенности было уделено внимание технологиям обработки пространственно-временных данных для их интеллектуального отслеживания, в том числе и в режиме реального времени, а также формальным абстрактным спецификациям не итеративных и итеративных подходов и обобщающих стратегий при обработке больших данных;

– задачами прогнозирования ВР занимались Грицай А.С., Затонский А.В., Надтока И.И., Федоров И.В., Филимонов Н.Б., Juyong L., Hadjout D., Hai-Bao C., Nishant J., Xu R., Yang M., Yichen L., Ying S. и др. Углубленно рассматривались модели машинного и глубокого обучения при прогнозировании потребления электроэнергии, в том числе предлагалось и ансамблевое обучение с использованием трех разных моделей глубокого обучения: LSTM, GRU и TCN;

– задачами разработки СППР в различных областях занимались Аверченкова Е.Э., Антонов В.В., Вересников Г.С., Гвоздев В.Е., Гончаренко В.И., Гузаиров М.Б., Ильясов Б.Г., Кулида И.П., Маторин С.И., Павлов С.В., Сагитова Л.А., Тиханычев О.В., Юсупова Н.И., Chinyere N.O., Sutton R.T. и др. Рассматривались задачи разработки и внедрения СППР в различных областях, в том числе и электроэнергетике с целью информационной поддержки принятия управленческих решений (например, проведение энергосберегающих мероприятий).

Перечень исследователей по вышеперечисленным направлениям может быть существенно расширен, но в большинстве вышеперечисленных работ авторов не приводится полное описание комплексного применения возможностей разных типов ИНС для осуществления в режиме реального времени анализа и обработки поступающих данных, прогнозирования ВР для предсказания возможных ситуаций, реакции систем на внешние воздействия СПД с необходимой точностью выходных значений.

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

**Предметом исследования** являются модели и методы обработки информации в виде больших темпоральных данных и прогнозирования временных рядов на основе машинного и глубокого обучения (на примере электроэнергетики).

**Целью** диссертационной работы является повышение эффективности информационного сопровождения принятия управленческих решений в организации при проведении энергосберегающих мероприятий за счет нейросетевой обработки больших темпоральных данных с одновременным прогнозированием многомерных временных рядов.

#### **Задачи исследования:**

Для достижения поставленной в диссертационной работе цели необходимо решить следующие задачи:

1. Разработать метод и модель обработки информации для формирования исходного датасета рекуррентной нейронной сети с целью прогнозирования значений потребления электроэнергии.

2. Разработать метод и модель прогнозирования значений потребления электроэнергии с применением модифицированной рекуррентной нейронной сети для информационной поддержки принятия управленческих решений.

3. Разработать структурную схему системы управления процессом поддержки принятия управленческих решений в электроэнергетике и архитектуру прототипа СППР на основе предложенных методов и моделей, реализованных в виде отдельных модулей.

4. Разработать прототип СППР в виде алгоритмического и программного обеспечения на основе нейросетевой обработки больших темпоральных данных и прогнозирования временных рядов для предприятия электроэнергетической отрасли.

5. Оценить эффективность предложенных решений (обработка больших объемов сетевого потока данных и прогнозирование потребления электроэнергии) на примере предприятия электроэнергетической отрасли.

#### **Научная новизна и теоретическая значимость**

1. Предложен метод обработки информации, включающий анализ и фильтрацию сетевого потока больших темпоральных данных на основе модели импульсной нейронной сети. Метод *отличается тем*, что на основе порядкового подхода следования импульсов (сетевой поток данных большого объема на транспортном и/или прикладном уровнях), модифицированного метода обучения обратного распространения ошибки и реализации возможности реагирования нейронов на внешние воздействия формируются специализированные правила обработки данных путем их нормализации, денормализации и кодирования, тем самым повышая скорость и качество обработки информации, *что позволяет* решать задачи информационной поддержки принятия решений при поступлении больших объемов данных через внешний сетевой интерфейс за счет формирования специализированных правил обработки информации.

2. Предложен метод нейросетевой обработки больших данных и прогнозирования временных рядов, основанный на модели рекуррентной нейронной сети и ее модифицированном методе обучения. Метод *отличается тем*, что на основе модифицированного метода обучения обратного распространения ошибки путем внедрения в него полученных экспериментально и формализованных коэффициентов скорости обучения ИНС и чувствительности, а также модификации нейрона путем ввода специализированных коэффициентов учета аномалий (всплесков) во временных рядах повышается точность выходных прогнозных значений. *Это позволяет* повысить прогнозную точность (в зависимости от сезонности до 92–95%) временных рядов для решения задач информационной поддержки принятия управленческих решений.

3. Новизна структурной схемы, предложенной в рамках прототипа СППР, *заключается в четырехкаскадном контуре управления* – четырех замкнутых контурах, в которых на основе предложенных методов и моделей объединены возможности импульсной нейронной сети (ИМНС) и рекуррентной нейронной сети (РНС) с одновременной обработкой и анализом больших данных, представленных в виде сетевого потока информации. *Это позволяет* управлять процессом информационной поддержки принятия управленческих решений на основе обработки больших разнородных и темпоральных данных и прогнозирования временных рядов.

**Практическая значимость** работы заключается в том, что на основе разработанных методов создан прототип СППР для прогнозирования значений потребления электроэнергии в организациях энергетической отрасли, что

позволяет повысить точность экспертных заключений и уменьшает роль человеческого фактора при принятии решений в различных ситуациях. Результаты внедрены в следующих организациях: «ООО «Башкирэнерго» – «Кумертауские электрические сети» (г. Кумертау)»; «Павловская ГЭС Приуфимской ТЭЦ филиала ООО «БГК»»; ООО «Газпромнефть-Цифровые решения»; ФГБОУ ВО «Уфимский университет науки и технологий» – кафедра автоматизированных систем управления (г. Уфа).

Применение программной реализации разработанных методов позволило:

а) создать прогнозные модели на основе применений нейронной сети и оценки остаточного ресурса на основе динамики развития ситуации потенциальных инцидентов (отказов контролируемых узлов агрегатов), как следствие, прогноз состояния оборудования;

б) прогнозировать потребление электроэнергии. При этом разработанный прототип до 17,7% точнее относительно других ИНС и до 26,6% точнее относительно статистических/гибридных методов прогнозирования, что дает возможность расчета (коррекции) количества резервируемых энерго мощностей и более оптимизированного проведения энергосберегающих мероприятий.

#### **Положения, выносимые на защиту**

1. Метод и модель обработки информации в виде сетевого потока данных с применением импульсной нейронной сети для подготовки исходного датасета с целью прогнозирования значений потребления электроэнергии (п. 4 паспорта специальности 2.3.1).

2. Метод и модель прогнозирования многомерных временных рядов с применением рекуррентной нейронной сети для информационной поддержки принятия управленческих решений (п. 4 паспорта специальности 2.3.1).

3. Структурная схема системы управления процессом поддержки принятия управленческих решений в электроэнергетике на основе предложенных методов и моделей (п. 9 паспорта специальности 2.3.1).

4. Прототип СППР на основе нейросетевой обработки больших темпоральных данных и прогнозирования временных рядов (п. 10 паспорта специальности 2.3.1).

5. Оценка эффективности предложенных решений (обработка большого объема информации в виде сетевого потока данных и прогнозирование потребления электроэнергии) на примере предприятия электроэнергетической отрасли (п. 3 паспорта специальности 2.3.1).

#### **Достоверность результатов исследований.**

Достоверность научных результатов обусловлена корректным использованием методов системного анализа и математического моделирования, общей теории и проектирования систем, математического, компьютерного и нейросетевого моделирования в рамках обработки больших темпоральных данных на примере информации в виде сетевого потока данных и прогнозирования временных рядов в области электроэнергетики. Вводимые допущения по нагрузке на вычислительные ресурсы мотивировались проводимыми экспериментами и фактами, известными из практики.

#### **Апробация результатов.**

Основные материалы диссертационной работы докладывались и обсуждались на: международной научно-технической конференции «Перспективные информационные технологии», ПИТ-2017, Самара (2017); всероссийской научной конференции с международным участием

«Информационные технологии интеллектуальной поддержки принятия решений», Уфа (2021).

Разработанный прототип СППР апробирован в рамках автоматического формирования исходного датасета и прогнозирования потребления электроэнергии в: ООО «Башкирэнерго» – «Кумертауские электрические сети» (г. Кумертау) при проведении энергосберегающих мероприятий и резервирования энерго мощностей; Павловской ГЭС Приуфимской ТЭЦ филиала ООО «БГК» при внедрении автоматизированной системы предиктивной аналитики и диагностики; ООО «Газпромнефть-Цифровые решения» для мониторинга энергетического оборудования; учебном процессе ФГБОУ ВО «УУНиТ» для решения задачи моделирования, прогнозирования и управления с применением технологий искусственного интеллекта.

### **Связь исследований с научными программами.**

Исследования в данном направлении выполнялись в период с 2015 по 2024 годы на базе Уфимского государственного авиационного технического университета и Уфимского университета науки и технологий (приказ от 08.07.2022 № 644 «О реорганизации Башкирского государственного университета и Уфимского государственного авиационного технического университета в форме слияния и создания нового вуза...»): в 2021-2022 гг. в рамках основной части государственных заданий ВУЗам № FEUE-2020-0007 на базе Уфимского государственного авиационного технического университета; в 2023-2024 годах на базе Уфимского университета науки и технологий в рамках основной части государственных заданий ВУЗам № FEUE-2023-0007.

По теме диссертационного исследования опубликованы 10 научных работ, из них 5 статей в изданиях из перечня, утвержденного ВАК (4 издания входят в перечень RSCI – K1, 1 издание – K2) России; 2 статьи, входящие в международную базу Scopus (Q3); 3 статьи входят в другие издания. Получено 6 свидетельств о государственной регистрации программ для ЭВМ.

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

**Структура и объем работы.** Диссертация состоит из введения, четырех глав, заключения, списка использованных источников и приложений. Работа изложена на 194 страницах, в том числе: основной текст на 182 страницах, 33 таблицы, 39 рисунков, список использованных источников из 180 наименований на 22 страницах, 2 приложения на 12 страницах.

## **КРАТКОЕ СОДЕРЖАНИЕ РАБОТЫ**

**Во введении** дается характеристика проблематике обработки больших темпоральных и разнородных данных (БТиРД), для которой требуются новые методы поддержки принятия решений. Проведенный анализ существующих методов и алгоритмов при обработке больших данных с возможностью одновременного прогнозирования ВР показал, что зачастую они используют четко-структурированную информацию, при этом не задействуются алгоритмы комплексной (одновременной) обработки БТиРД.

В связи с этим **актуальность** диссертационного исследования обусловлена необходимостью разработки методов обработки больших темпоральных данных (БТД) и прогнозирования ВР с целью повышения

эффективности информационной поддержки принятия управленческих решений (например, проводить энергосберегающие мероприятия, начиная от контроля рабочих режимов и сроков проверки приборов учета электрической энергии и заканчивая реконструкцией электрических сетей, а также резервированием генерирующих мощностей электроэнергетических систем), что позволяет повысить точность экспертных заключений и уменьшает роль человеческого фактора при принятии решений в различных ситуациях.

**Первая глава** посвящена анализу существующих методов обработки больших данных для поддержки принятия решений на примере обработки больших объемов СПД и прогнозирования ВР. Отмечено, что с точки зрения обеспечения качественной обработки больших данных основными проблемами являются их классификация, темпоральность (привязка данных по дате в рамках предобработки информации) и анализ (предобработка), на выходе которого получаем массив нормализованных данных. Классификация представляет собой контролируемое машинное обучение, решающее проблему построения модели из правильно классифицированного набора данных. Несмотря на то, что в литературе на сегодняшний день есть огромное множество алгоритмов (методов) и моделей классификации, регрессии, в том числе и прогнозирования (статистические – регрессионные, модели Грея, гибридные модели и нейросетевые), их комплексное использование в самых различных областях не является целесообразным по причине невозможности обработки БТиРД для различных выборок. Одним из способов решения этой проблемы для электроэнергетики является разработка нескольких математических моделей классификации и регрессии, а также построение интегрированного универсального метода обработки данных путем объединения и модификации указанных моделей для повышения эффективности принятия управленческих решений.

В рамках проведенных исследований в диссертации представлен сравнительный анализ моделей и методов обработки больших данных с возможностью прогнозирования ВР: статистические методы, модели Грея, гибридные и нейросетевые методы. Наиболее подробно рассмотрены нейросетевые методы, основными преимуществами которых являются скорость обучения и высокая точность раннего прогнозирования ВР и обработки больших данных. Тем не менее, к общим недостаткам этих традиционных и модифицированных моделей следует отнести отсутствие фиксированных характеристик, например, асимметричные циклы и случайные выбросы (аномалии) наблюдений, существующие в реальных ВР, а также невозможность обработки разнородных данных (РД) в исходном виде (например, разнородный СПД).

При всем этом у вышеперечисленных методов и моделей обработки больших данных и прогнозирования ВР имеются четыре серьезных общих ограничения в рамках рассматриваемой предметной области:

1) специфичность и узконаправленность: каждую модель и методы придется перепроектировать для каждого конкретного случая в рамках прогнозирования ВР;

2) ресурсоемкость модели прогнозирования;

3) отсутствие формализованной и технической реализации обработки БТиРД (например, данные в виде разнородного СПД из разных сетей) с одновременным прогнозированием одномерных и многомерных ВР с учетом



необходимых зависимостей на этапе предобработки данных. Как следствие, присутствие разностной аппроксимации входных параметров объекта;

4) отсутствие необходимого этапа предобработки информации, на выходе которого получаем качественный исходный датасет для обучения ИНС с учетом зависимостей между данными: информация о температуре с датчиков, выходные дни, конец месяца и т.д. Следовательно, отсутствуют сбор информации, ее организация и анализ, а также обнаружение и идентификация требуемого информационного блока в больших темпоральных массивах данных.

Таким образом, указанные проблемы и недостатки существующих решений определили цель и задачи диссертационного исследования.

**Вторая глава** посвящена разработке методов нейросетевой обработки больших РД и прогнозирования ВР с применением импульсной (третье поколение ИНС) и рекуррентной нейронных сетей (второе поколение ИНС) на основе модифицированного метода обучения обратного распространения ошибки для информационной поддержки принятия решений на примере электроэнергетики.

Предлагаемые методы включают в себя:

1. Метод нейросетевой обработки БТД и новый метод обучения на примере анализа и обработки (фильтрации) информации в виде СПД с применением модели импульсной нейронной сети. За счет внедрения метода порядкового следования импульсов и добавления коэффициента реагирования каждого нейрона входного слоя на изменение данных, в том числе видов и типов информации, представленной в виде СПД, повышается скорость и качество (Data Quality – точность и своевременность) обработки большого объема данных на различных уровнях модели OSI с последующим формированием специализированных правил обработки информации. При этом приоритет по обработке БТД отдается импульсной нейронной сети из-за ее математического аппарата (есть возможность оперирования дискретными событиями и обработки разнородных и временных – темпоральных данных), способствующего высокой скорости обработки данных, динамичности и многозадачности.

Одним из основных параметров воздействия на принятие решений в электроэнергетике являются данные (информация, поступающая по сетевым каналам через внешний сетевой интерфейс), передаваемые от хоста ( $h$ ) к клиенту ( $c$ ), в нашем случае – на физические серверы кластера за определенный период времени  $t$ . В этой связи введем обозначения  $N_c^h(t)$  – темпоральные данные с внешнего сетевого интерфейса, передаваемые с хоста  $h$  (счетчиков и датчиков) клиенту  $c$  за определенный период времени  $t$ , при этом  $h=1, \dots, n$  и  $c=1, \dots, k$  ( $n$  – общее количество хостов, с которых передается СПД,  $k$  – количество физических серверов в кластере – клиентов). Задача обработки БТД заключается в том, чтобы за определенный период времени  $t$  обработать максимальное количество данных  $N_c^h$  с внешнего сетевого интерфейса для формирования исходного датасета за счет правил фильтрации и минимизации рисков несвоевременного реагирования на изменение ситуации, в частности, потери работоспособности клиента  $c$ . Решать данную задачу предлагается в четыре этапа: предобработка данных, формирование модели нейронной сети, постобработка данных и принятие решения.

На первом этапе, выполняющимся каждый час –  $i$  (согласно проведенным исследованиям и по причине установленной периодичности передачи данных, а также изменения видов и типов входящего СПД), т.е.  $i = 24$  обучения в сутки, мы

формируем архитектуру нейронной сети, осуществляя выбор параметров импульсной нейронной сети: наработанная база правил фильтрации; общее количество нейронов и слоев (в том числе и промежуточных); количество нейронов на входном, промежуточном и выходном слоях.

На этапе формирования модели нейронной сети (второй этап) происходит обучение PNN (Pulsed Neural Network) на основе доработанного под импульсную нейронную сеть (ИмНС) метода обратного распространения ошибки. Основная суть заключается в накоплении потенциала в мембране нейрона за счет полученных на вход импульсов (спайков). Исходя из этого, если накопленный потенциал достигает порогового значения (в нашем случае – 1), то нейрон активируется и пропускает импульс (спайк) в следующий слой с последующим уменьшением своего потенциала (обозначим данный процесс как  $P$ ) до минимального значения (в нашем случае – 0), что описывается уравнениями:

$$P_{j,p} = \frac{d\alpha(j,p)}{dt} = -\alpha(j,p) + I(j,p), \quad (1)$$

$$I(j,p) = w_{jp} \cdot \sum_{i=1}^d \varphi(p,i), \quad (2)$$

$$\varphi(p,i) = \begin{cases} 1, & \text{если } t_p = t_i \\ 0, & \text{иначе} \end{cases}, \quad (3)$$

где  $I(j,p)$  – взвешенная сумма входных импульсов (спайков) в текущий момент времени ( $t_p$ ) на каждом на  $j$ -ом нейроне,  $\varphi(p,i)$  – индикатор (переключатель) уровня потенциала в процессе  $P_{j,p}$ ,  $w_{jp}$  – весовой синаптический коэффициент на каждом на  $j$ -ом нейроне,  $\alpha(j,p)$  – потенциал  $j$ -го нейрона во время угасания  $p$ -го импульса.

Важно отметить, что группы импульсов представляют собой входные паттерны. Соответственно, чтобы сгенерировать импульсные входы, необходимо их распределить в специализированные спайковые группы по Пуассону и подать в сеть. Исходя из (2) и принятых обозначений общая, общая взвешенная сумма входных спайковых групп  $S$  описывается как

$$S = \sum_{j=1}^{m-1} \sum_{p=1}^d I(j,p).$$

При этом утечка потенциала на выходном слое учитывается разницей в утечке потенциала в текущий момент времени ( $t$ ). Исходя из вышеописанного

описываем функцию активации  $f(j,p)$ :  $f(j,p) = \sum_{i=1}^d \exp\left(-\frac{t_p - t_i}{P_{j,p}}\right)$ ,  $j = \overline{(1, \dots, m)}$ ,  $p = \overline{(1, \dots, d)}$ ,

а сами весовые коэффициенты рассчитываются по модифицированному для РНС (второе поколение) методу обратного распространения ошибки.

В разработанной ИмНС за основу берется модель Фитц Хью-Нагумо, которая представляет собой упрощенную модель, воспроизводящую основные свойства волн возбуждения в модели Ходжкина-Хаксли и содержит две переменные: быструю переменную, соответствующую мембранному потенциалу в полной модели, и медленную переменную, заключающуюся в значении восстановления мембранного потенциала. Внесены изменения, суть которых состоит в том, что в отличие от оригинальной модели добавлена возможность реагирования каждого нейрона на внешние воздействия (в нашем случае — на изменение видов и типов СПД), как следствие, на динамику модели

(структура нейрона представлена на рисунке 1) с нелинейным поведением восстанавливающей переменной.

На рисунке 1:  $j$  – порядковый номер нейрона;  $j = (\overline{1, \dots, m})$ , где  $m$  – это общее число нейронов;  $\alpha'(j)$  – начальный потенциал  $j$ -го нейрона;  $p$  – порядковый номер импульса,  $p = (\overline{1, \dots, d})$ , где  $d$  – это количество импульсов;  $\alpha(j, p)$  – потенциал  $j$ -го нейрона во время угасания  $p$ -го импульса;  $\omega(j, p)$  является постоянной восстановления потенциала  $j$ -го нейрона в результате  $p$ -го импульса;  $t_p$  – время угасания  $p$ -го импульса;  $f(j)$  – значение функции активации  $j$ -го нейрона (4).

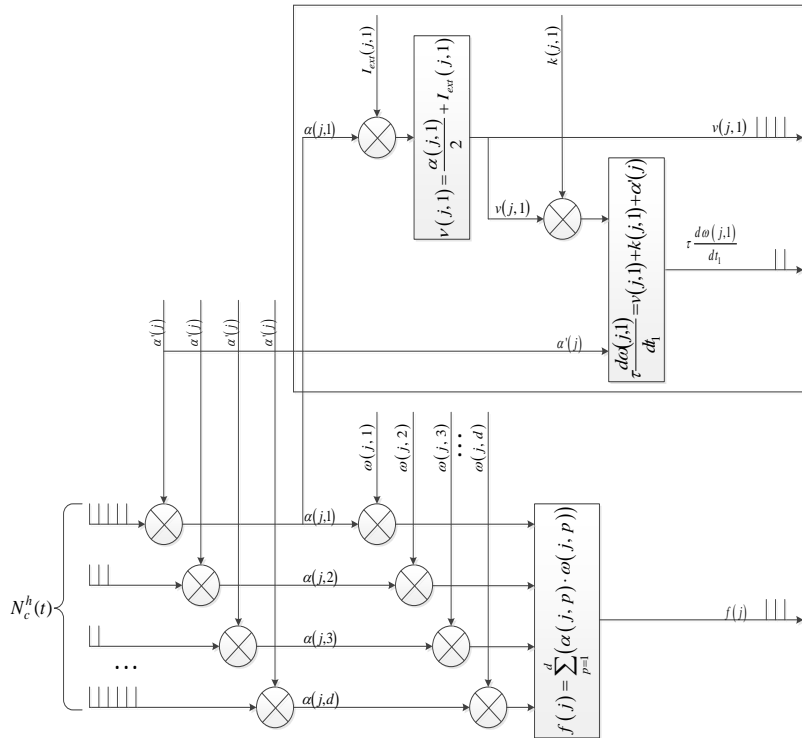


Рисунок 1 – Структура нейрона в разработанной ИМНС

$$f(j) = \sum_{p=1}^d (\alpha(j, p) \cdot \omega(j, p)). \quad (4)$$

Данная модель нейрона описывается следующей системой уравнений:

$$\begin{cases} v(j, p) = \frac{\alpha(j, p)}{2} + I_{ext}(j, p) \\ \tau \frac{dv(j, p)}{dt_p} = v(j, p) + k(j, p) + \alpha'(j) \end{cases}, \text{ при } p = (\overline{1, \dots, d}), j = (\overline{1, \dots, m}), \quad (5)$$

где  $I_{ext}(j, p)$  – постоянная константа внешнего воздействия  $p$ -го импульса на  $j$ -й нейрон;  $t_p$  – время угасания  $p$ -го импульса;  $k(j, p)$  – постоянная константа реагирования  $j$ -го нейрона на  $p$ -й импульс;  $v(j, p)$  – функция динамики мембранного потенциала  $j$ -го нейрона от воздействия  $p$ -го импульса;  $\tau$  – временная постоянная корреляции шума.

В рамках диссертационного исследования получены результаты, подтверждающие, что предложенный метод обучения существенно увеличивает

скорость и точность обучения импульсной нейронной сети для обработки БТиРД.

2. Метод интеллектуальной обработки и анализа БТД и прогнозирования ВР с применением РНС второго поколения на основе модифицированного метода обучения обратного распространения ошибки путем внедрения в него разработанных коэффициентов скорости обучения и чувствительности, а также модификации нейрона за счет ввода коэффициента учета аномалий (всплесков) во ВР для увеличения точности расчета прогнозных значений. В рамках данной диссертационной работы прогнозирование осуществлялось на примере потребления электроэнергии энергетических предприятий Республики Башкортостан с учетом обработки БТД.

Сам процесс прогнозирования, в который входит и обработка БТД, предлагается проводить в четыре этапа: принятие решения о прогнозировании, т.е. лицо, принимающее решение (ЛПР), принимает решение, на какое количество дней будет осуществлен прогноз; предобработка данных; формирование прогнозной модели; постобработка данных.

Введем обозначения:  $EE_{ji}^k$  – значение потребляемой электроэнергии, измеренное на  $k$ -ом счетчике на  $i$ -ую дату  $j$ -го года. Здесь  $k=1, \dots, n$ , где  $n$  – количество электросчетчиков, участвующих в расчетах,  $j$  – номер года,  $i$  – конкретная дата измерения.

**Вычисление среднеквадратичной ошибки.** Как правило, входы сети рассматриваются как входной вектор  $(\overline{EE}_{ji}^k)$ , где  $\overline{EE}_{ji}^k = [Ee_{j1}^k, Ee_{j2}^k, \dots, Ee_{jK}^k]$ , а выходы сети можно представить в качестве вектора выхода  $(\overline{EE}_{ji}^k)$ , где  $\overline{EE}_{ji}^k = [Ee_{j1}^k, Ee_{j2}^k, \dots, Ee_{jL}^k]$ , при этом  $K=1, \dots, M$ , а  $L=1, \dots, N$ , в которых  $M$  и  $N$  представляют собой размерность входного и выходного векторов. Соответственно, обучающая выборка представляет собой множество пар  $R$  выходных векторов  $\overline{Ee}_{ji}^k$  и желаемых (эталонных) выходных векторов  $\overline{Ee}_{ji}^k$ :

$$R = \{(\overline{Ee}_{j1}^k, \overline{Ee}_{j1}^k), (\overline{Ee}_{j2}^k, \overline{Ee}_{j2}^k), \dots, (\overline{Ee}_{jL}^k, \overline{Ee}_{jL}^k)\}. \quad (6)$$

Отсюда может быть произведен расчет фактического выхода  $\overline{Ee}_{jiL}^k$  выходного слоя:  $\overline{Ee}_{jiL}^k = f(\sigma_L)$ , где  $\sigma_L$  – взвешенная сумма входов нейрона  $L$ ,  $f$  – функция активации для нейронов промежуточных слоев, определяющаяся по соотношению:

$$\sigma(\sigma_L) = \frac{1}{1 + \exp(-\sigma_L)} \quad (7)$$

и является функцией от взвешенной суммы входов нейрона  $EEH_j$  в каждом промежуточном слое  $L_h$ . Тогда можем вычислить номер слоя  $z$  для нейрона с номером  $l$  по формуле с целочисленным делением  $z = \lfloor l / N_{il} \rfloor + 1$ . Взвешенная сумма для нейронов промежуточных слоев и выходного слоя может быть представлена формулой:

$$\sigma_L = \begin{cases} \sum_{n=1}^{N_{il}} (w_{nl} \overline{Ee}_{jn}^k), \text{ при } z = 1 \\ \sum_{n=(z-2)*N_{il}+1}^{n=(z-1)*N_{il}} (w_{nl} EEH_{jn}), \text{ при } z > 1 \end{cases}, \quad (8)$$

где  $w_{nl}$  – вес синапса (вес связи, соединяющей нейрон  $n$  нейроном  $l$ ),  $l$  – нейрон в промежуточном слое.

Исходя из этого, мы можем определить среднеквадратичную ошибку для каждой пары векторов множества  $R$  путем суммирования среднеквадратичных ошибок в каждом выходном нейроне:

$$E_k^{ji} = \sqrt{\frac{1}{L} \sum_{l=1}^L (\overline{Ee_{jil}^k} - \overline{Ee_{jil}^k})^2}, \quad (9)$$

и, как следствие, полную среднеквадратичную ошибку  $E$  путем суммирования всех  $E_k^{ji}$  для каждого значения всех  $k$  счетчиков ( $k = 1, \dots, n$ ) и всех дат измерений в обучающей выборке.

Таким образом, цель обучения состоит в минимизации  $E$  за счет нахождения соответствующего набора весов связи, соединяющей нейрон с нейроном (8).

**Определение частных производных по весам синапсов.** Исходя из соотношения (10) можем отметить, что

$$\frac{dE}{dw_{nl}} = \overline{Ee_{ji,l}^k} - \overline{Ee_{ji,l}^k}, \quad (10)$$

при этом, опираясь на (8), мы получаем

$$\frac{d\sigma_{L_h}}{dw_{nl}} = \sum_{n=(z-2)*N_{il}+1}^{(z-1)*N_{il}} E E H_{jn}. \quad (11)$$

Исходя из (10) и (11), определяем частную производную  $E$  по весу  $w_{nl}$  для выполнения в (12) градиентного спуска для весов синапсов между промежуточным и выходным слоями:

$$\frac{dE}{dw_{nk}} = \sum_{l=1}^L ((\overline{Ee_{ji,l}^k} - \overline{Ee_{ji,l}^k}) \cdot \overline{Ee_{ji,l}^k}) \cdot ((\sigma(\overline{Ee_{ji,l}^k}) - \overline{Ee_{ji,l}^k}) \cdot E E H_{jn}). \quad (12)$$

При этом если рассматривать частный случай производной  $E$  между входным и промежуточными слоями, все выходы зависят от  $w_{jk}$  и частная производная будет находиться следующим образом:

$$\frac{dE}{dw_{nk}} = \sum_{l=1}^L ((\overline{Ee_{ji,l}^k} - \overline{Ee_{ji,l}^k}) \cdot \overline{Ee_{ji,l}^k}) \cdot ((\sigma(\overline{Ee_{ji,l}^k}) - \overline{Ee_{ji,l}^k}) \cdot (w_{nk} \cdot E E H_{jn})) \cdot ((1 - E E H_{jn}) \cdot \overline{Ee_{ji,l}^k}). \quad (13)$$

Таким образом, уравнения (10) и (11) дают все необходимые величины  $\frac{dE}{dw_{nl}}$  для применения (12) и (13) в рамках градиентного спуска для всех весов нейронной сети.

**Изменение весов синапсов.** Каждый вес будет изменен на  $dw$  для уменьшения  $E$ :

$$w_{nl}(t+1) = w_{nl}(t) + \Delta w_{nl}(t), \quad (14)$$

где  $\Delta w_{nl}(t) = - \left. \frac{dE}{dw_{nl}} \right|_t$ ,  $w_{nl}(t)$  – вес синапса во время  $t$ ,  $w_{nl}(t+1)$  – измененный

(обновленный) вес синапса. Далее для увеличения скорости обучения нейронной сети, добавляется параметр  $\alpha$  – learning rate, а для повышения точности расчетов прогнозных значений задается специализированный коэффициент чувствительности  $\varphi$ :

$$\Delta w_{nl}(t) = - \left. \frac{dE}{dw_{nl}} \right|_t + (\varphi \cdot (\alpha \cdot \Delta w_{nl}(t-1))). \quad (15)$$

Основной смысл изменения заключается в создании диапазона весов синаптических связей (весовых коэффициентов)  $\varphi \in [0.1; 0.9]$ . Это позволит избежать резких колебаний значений в матрице весовых коэффициентов, что является необходимым условием повышения точности расчета прогнозных значений.

На третьем этапе производится непосредственно формирование прогнозной модели и расчет прогнозных значений, а на четвертом этапе – денормализация полученных прогнозных значений  $EE_{ji+l}^k$  в связи с изначальной нормализацией данных ( $EE_{ji}^k \in [0;1]$ ):  $EE_{ji}^k = Ee_{ji}^k \cdot (Ee_{\max} - Ee_{\min}) + Ee_{\min}$ .

Таким образом, исходя из теоретических результатов, полученных в главе 2, реализованы и апробированы методы и модели, что показано в главах 3 и 4.

**Третья глава** посвящена разработке архитектуры и алгоритмов прототипа СППР на основе нейросетевой обработки БТД и прогнозирования ВР. Показаны схема работы прототипа СППР и входящие в ее состав модули, а также области применения.

В целях информационной поддержки принятия решений должны выполняться следующие основные задачи: прогнозирование ВР и генерация правил фильтрации СПД на основе автоматизированной обработки больших данных; автоматический мониторинг состояния серверного оборудования.

Предлагаемые методы и модели апробировались путем публикации в научно-технических журналах, практической реализации и регистрации разработанных программных продуктов. В рамках текущей диссертации предлагаемый прототип СППР направлен на информационное сопровождение принятия управленческих решений на основе обработки БТиРД и прогнозирования ВР в электроэнергетике.

Структурная схема системы управления процессом информационной

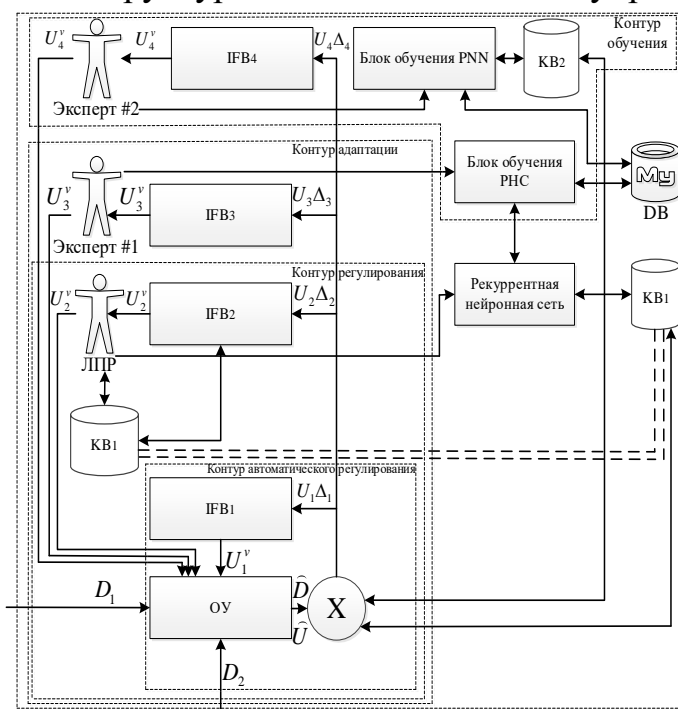


Рисунок 2 – Контур управления функциональным процессом прогнозирования потребления электроэнергии с включением СППР

поддержки принятия управленческих решений представлена в виде контура управления на рисунке 2. На рисунке: ОУ – объект управления представленного прототипа СППР; IBF<sub>1</sub>, IBF<sub>2</sub>, IBF<sub>3</sub>, IBF<sub>4</sub> – блоки формирования воздействия; DB (Database) – база данных MySQL; KB<sub>1</sub>, KB<sub>2</sub> – базы знаний, получаемые в результате обработки ретроспективных данных;  $\Delta_1, \Delta_2, \Delta_3, \Delta_4$  – ситуации для принятия решений;  $\hat{D} = \{D_1, D_2\}$ , где  $D_1$  – внешний сетевой поток данных и ретроспективные данные,  $D_2$  – внешнее возмущающее воздействие;  $\hat{U} = \{U_1^v, U_2^v, U_3^v, U_4^v\}$  – варианты управляющего воздействия на ОУ, где  $v$  – текущая ситуация, при этом

$v = 1, \dots, n$ , где  $n$  – количество ситуаций.

Критериями эффективности прототипа СППР являются высокая скорость обработки больших данных и точность прогнозных значений ВР, что позволяет повысить эффективность принятия управленческих решений на предприятиях энергетического сектора. В структурной схеме (контуре) управления реализованы основные механизмы (функции) элементов замкнутых систем передачи информации: анализ данных и прогнозирование ВР с изменяющимися глубиной и горизонтом; процесс принятия решения; анализ оценки нагрузки системы; удаленная передача данных.

**Четвертая глава** посвящена апробации и оценке эффективности предложенного комплекса методов, реализованных в виде прототипа СППР.

Приводятся результаты экспериментальных исследований, демонстрирующих, что использование разработанной СППР является целесообразным и эффективным при обработке БТиРД и прогнозировании ВР на примере значений потребления электроэнергии. Проведенные анализы эффективности показали, что при использовании предлагаемого прототипа СППР получаем:

– возможность идентификации СПД при смене его вида и типа на основе метода нейросетевой обработки больших данных за счет модели импульсной нейронной сети. При этом использование ИмНС при обработке БТиРД на примере обработки внешнего сетевого потока данных является эффективным и целесообразным за счет генерации на выходе нейронной сети правил фильтрации обработки СПД. Но при распределенной обработке больших объемов данных оптимизация, в том числе и снижение нагрузки также является важным аспектом при работе любой системы, в связи с чем было выявлено, что средняя нагрузка на центральный процессор варьируется от 0,3% до 6,9%. Таким образом, предложенный метод позволяет реализовать упреждающее реагирование на аномалии в СПД, а также отфильтровывать СПД для формирования исходного датасета, что открывает возможность применения в различных системах управления для информационной поддержки принятия решений;

– предлагается метод обработки больших разнородных данных РНС на примере прогнозирования ВР, основанный на модели ИНС второго поколения. Эксперименты показали преимущество предлагаемого решения в рамках прогнозирования потребления электроэнергии: до 17,7% точнее относительно других ИНС и до 34% точнее относительно статистических/гибридных методов прогнозирования, а также до 95% быстрее относительно других методов обучения ИНС. Это достигается модификацией нейрона и метода обучения рекуррентной нейронной сети, а также качественным исходным датасетом, получаемым импульсной нейронной сетью. Данные результаты показывают эффективность ее применения в расчетах прогнозных значений количества потребляемой электроэнергии. При этом за счет данных прогнозов у предприятий появится возможность принимать управленческие решения: например, проводить энергосберегающие мероприятия, начиная от контроля рабочих режимов и сроков проверки приборов учета электрической энергии и заканчивая реконструкцией электрических сетей, а также резервированием генерирующих мощностей электроэнергетических систем.

## ОСНОВНЫЕ ВЫВОДЫ И РЕЗУЛЬТАТЫ РАБОТЫ

1. Разработаны метод и модель обработки СПД с применением импульсной нейронной сети для информационной поддержки принятия управленческих решений. Разработанный метод и нейросетевая модель позволяют качественно и эффективно осуществлять информационную поддержку принятия управленческих решений при поступлении больших объемов СПД через внешний сетевой интерфейс за счет формируемых на выходе правил фильтрации, низкой загруженности серверных ресурсов (CPU: 0,3-6,9%; RAM: 0,4-4,0%; SSD: 0,5-3,1%) и качественной обработки больших данных, что позволяет автоматически формировать исходный датасет для прогнозирования потребления электроэнергии рекуррентной нейронной сетью. Данный результат достигается в том числе и методом обучения импульсной нейронной сети, за счет которого ИМНС с «нуля» обучается за 20 минут.

2. Разработаны метод и модель прогнозирования многомерных ВР с применением модели рекуррентной нейронной сети для информационной поддержки принятия управленческих решений. Данный метод за счет модифицированного метода обучения и высокой точности прогнозных значений позволяет оперативно и эффективно осуществлять информационную поддержку принятия управленческих решений. При этом модифицированные нейрон и метод обучения позволили получить прогнозные значения высокой точности (до 17,7% точнее относительно других ИНС) и повысить скорость обучения на 83–95%, а эффективность метода и модели экспериментально подтверждена на реальном массиве ретроспективных данных, полученным в результате обработки СПД, при этом средняя величина ошибки не превышала 7,8%.

3. Разработана четырехкаскадная структурная схема (контур) системы управления процессом информационной поддержки принятия управленческих решений в электроэнергетике, включающая в себя два контура обучения, контур адаптации и контур регулирования на основе которых реализован комплекс задач информационной поддержки с целью повышения эффективности принятия управленческих решений на примере решения задач обработки больших объемов СПД и расчета прогнозных значений потребления электроэнергии. Показаны архитектура прототипа СППР и алгоритмы работы ее модулей.

4. Разработан прототип СППР на основе нейросетевой обработки БТД и прогнозирования ВР. Разработанное программное обеспечение позволяет свести к минимуму риски финансовых убытков предприятия за счет принятия решений ЛПР и содержит в себе следующие функции: информационная поддержка принятия управленческих решений на основе автоматизированной обработки больших разнородных и темпоральных данных; на основе автоматизированной обработки больших данных и разработанных методов и моделей, представленных в главе 2, прогнозирование ВР и генерация правил фильтрации СПД.

5. Выполнена оценка эффективности предложенных решений, реализованных в виде прототипа СППР на примере реального массива ретроспективных данных и СПД организации электроэнергетики, показывающая эффективность и целесообразность применения предлагаемой СППР. Средняя точность прогноза прототипа СППР (модель рекуррентной ИНС) составляет 92,2%, а относительная эффективность предлагаемого прототипа СППР прогнозирования точнее остальных методов на 38,4–84,7%. Следовательно, чем



меньше необоснованный процент резервирования энергетических мощностей, тем меньше финансовых потерь, что является особенно полезным в текущих экономических реалиях.

Созданный в ходе работы прототип СППР на основе обработки больших данных и прогнозирования ВР имеет перспективы дальнейшего развития в рамках доработки математических моделей, увеличения функциональности и полной реализации собственной библиотеки Deep Learning на языке программирования Java, а разработанные методы позволяют подстроить прототип СППР под широкий класс задач, в которых необходимы автоматическое формирование датасетов и ранний расчет прогнозных значений.

## ОСНОВНЫЕ ПУБЛИКАЦИИ ПО ТЕМЕ ДИССЕРТАЦИИ

### *Статьи в научных изданиях из Перечня рецензируемых научных изданий, рекомендованных ВАК, либо в научных изданиях, индексируемых базой данных RSCI*

. Пальчевский, Е.В. Разработка удаленного клиента для автоматизированной передачи данных в UNIX-подобных системах / Е.В. Пальчевский, А.Р. Халиков // Программные продукты и системы. – 2019. – Т. 32. № 1. – С. 92–102.

. Пальчевский, Е.В. Прогнозирование на основе искусственной нейронной сети второго поколения для поддержки принятия решений в особо значимых ситуациях / Е.В. Пальчевский, В.В. Антонов, Р.Р. Еникеев // Программные продукты и системы. – 2022. – Т. 35. № 3. – С. 488–503.

3. Palchevsky, E.V. An intelligent system for monitoring and analyzing competencies in the learning process / E.V. Palchevsky, G.G. Kulikov, V.V. Antonov, L.E. Rodionova, A.R. Fakhrullina, L.A. Kromina, T. Breikin // Software & Systems. – 2023. – No. 1. – P. 5-13.

. Пальчевский, Е.В. Метод формирования структур цифровых двойников предметно-ориентированных объектов пространственно-открытых источников на основе формализмов теории множеств, графов, теории категорий и теории порождающих языков Хомского / В.В. Антонов, Г.Г. Куликов, Я.С. Вояковская, Е.В. Пальчевский // Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника. – 2023. – Т. 23. №2. – С.17–27.

5. Palchevsky, E. V. Method for Improving the Accuracy of Predictive Values of Time Series Based on the Imputation of Historical Data / E. V. Palchevsky // Programmnaya Ingeneria. – 2023. – Vol. 14, No. 6. – P. 301-306.

### *Публикации в отечественных журналах из перечня изданий ВАК, включенных в международные базы Web of Science, Scopus*

6. Пальчевский, Е.В. Концепция формирования интеллектуальных управляющих систем энергоснабжения городских сетей / Е.В. Пальчевский, В.В. Антонов, Л.Е. Родионова, Л.А. Кромина, А.Р. Фахруллина, Л.И. Баймурзина, Е.А. Родионов // Мехатроника, автоматизация, управление. – 2023. – Т. 24. № 4. – С. 190-198.

7. Пальчевский, Е.В. Intelligent forecasting of electricity consumption in managing energy enterprises in order to carry out energy-saving measures / E.V. Palchevsky, V.V. Antonov, L.A. Rodionova, L.A. Kromina, A.R. Fakhrullina // Mechatronics, Automation, Control. – 2023. – Vol. 24, No. 6. – P. 307-316.

***Другие публикации по теме диссертации***

8. Пальчевский, Е.В. Разработка системы увеличения пропускной способности сетевого стека для повышения отказоустойчивости физического сервера / Е.В. Пальчевский, А.Р. Халиков // Перспективные информационные технологии. – 2017. – С. 262–265. (РИНЦ, по материалам конференции «ПИТ-2017»)

9. Palchevsky, E. V. Decision Support System based on Application of the Second Generation Neural Network / E. V. Palchevsky, V. V. Antonov // Programmaya Ingeneria. – 2022. – Vol. 13, No. 6. – P. 301-308. (по материалам конференции «ITIDS-2021»)

10. Palchevsky, E.V. Artificial Neural Network for Forecasting Electricity Consumption in Energy Enterprises / E.V. Palchevsky, V.V. Antonov, L.E. Rodionova, A.R. Fakhrullina, L.A. Kromina // Programmaya Ingeneria. – 2023. – Vol. 14, No. 1. – P. 34-41.

***Патенты и свидетельства о регистрации программ для ЭВМ***

11. Пальчевский, Е.В. Свидетельство о государственной регистрации программы для ЭВМ № 2017612872 «Расчет количества входящих потоковых сетевых пакетов» / Е.В. Пальчевский // Зарег. 03.03.17. – М.: Роспатент, 2017.

12. Пальчевский, Е.В. Свидетельство о государственной регистрации программы для ЭВМ № 2017613016 «Система управления серверами в веб-интерфейсе» / Е.В. Пальчевский // Зарег. 07.03.17. – М.: Роспатент, 2017.

13. Пальчевский, Е.В. Свидетельство о государственной регистрации программы для ЭВМ № 2017613065 «Распараллеливание нагрузки физических и логических ядер» / Е.В. Пальчевский // Зарег. 09.03.17. – М.: Роспатент, 2017.

14. Пальчевский, Е.В. Свидетельство о государственной регистрации программы для ЭВМ № 2017613861 «Мониторинг состояния вычислительного процесса» / Е.В. Пальчевский // Зарег. 03.04.17. – М.: Роспатент, 2017.

15. Пальчевский, Е.В. Свидетельство о государственной регистрации программы для ЭВМ № 2017614111 «Разработка алгоритма блокировки IP-адреса» / Е.В. Пальчевский // Зарег. 06.04.17. – М.: Роспатент, 2017.

16. Свидетельство о государственной регистрации программы для ЭВМ № 2023662065 «Программная библиотека глубокого обучения для решения регрессионных задач» / Е.В. Пальчевский, В.В. Антонов // Зарег. 06.06.23. – М.: Роспатент, 2023.

Диссертант

Е.В. Пальчевский