



**НАУЧНЫЙ
ФОРУМ**
nauchforum.ru

ISSN: 2541-8394



№2(93)

**НАУЧНЫЙ ФОРУМ:
ТЕХНИЧЕСКИЕ И ФИЗИКО-
МАТЕМАТИЧЕСКИЕ НАУКИ**

МОСКВА, 2026



НАУЧНЫЙ ФОРУМ: ТЕХНИЧЕСКИЕ И ФИЗИКО- МАТЕМАТИЧЕСКИЕ НАУКИ

*Сборник статей по материалам ХСШ международной
научно-практической конференции*

№ 2 (93)
Февраль 2026 г.

Издается с декабря 2016 года

Москва
2026

УДК 51/53+62

ББК 22+3

Н34

Председатель редакционной коллегии:

Лебедева Надежда Анатольевна – доктор философии в области культурологии, профессор философии Международной кадровой академии, член Евразийской Академии Телевидения и Радио.

Редакционная коллегия:

Мартышкин Алексей Иванович – канд. техн. наук, доцент, доцент кафедры «Вычислительные машины и системы» Пензенского государственного технологического университета;

Немирова Любовь Федоровна – канд. техн. наук, доц. кафедры конструирования и технологии изделий легкой промышленности, ГБОУ ВПО «Омский государственный технический университет», ООО «МИНСП»;

Старченко Ирина Борисовна – д-р техн. наук, профессор, эксперт РАН, зам. директора по учебно-научной работе, Политехнический институт (филиал) ДГТУ в г. Таганроге;

Усманов Хайрулла Сайдуллаевич – д-р техн. наук, доцент, Ташкентский институт текстильной и легкой промышленности, Республика Узбекистан, г. Ташкент.

Н34 Научный форум: Технические и физико-математические науки: сб. ст. по материалам ХСШ междунар. науч.-практ. конф. – № 2 (93). – М.: Изд. «МЦНО», 2026. – 22 с.

ISSN 2541-8394

Статьи, принятые к публикации, размещаются на сайте научной электронной библиотеки eLIBRARY.RU.

ББК 22+3

ISSN 2541-8394

© «МЦНО», 2026

Оглавление

Раздел 1. Технические науки	4
1.1. Информатика, вычислительная техника и управление	4
СРАВНЕНИЕ ТОЧНОСТИ КРАТКОСРОЧНОГО И ДОЛГОСРОЧНОГО ПРОГНОЗИРОВАНИЯ СПРОСА НА ТРАНСПОРТНЫЕ УСЛУГИ С ИСПОЛЬЗОВАНИЕМ ИНТЕЛЛЕКТУАЛЬНЫХ МЕТОДОВ Бокарев Дмитрий Вячеславович	4
ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И 1С: ПОМОЩНИК ИЛИ ЗАМЕНА СПЕЦИАЛИСТАМ? Петрова Мария Владимировна Слепушкина Анастасия Александровна	9
1.2. Энергетика	13
ПРИМЕНЕНИЕ ГРАФОВЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АНАЛИЗА И ОПТИМИЗАЦИИ ПОТОКОРАСПРЕДЕЛЕНИЯ В РАСПРЕДЕЛИТЕЛЬНЫХ СЕТЯХ: ПОСТАНОВКА ЗАДАЧИ В КОНТЕКСТЕ РОССИЙСКОЙ ЭНЕРГЕТИКИ И БОЛЬШИХ ДАННЫХ Королев Владислав Игоревич	13

РАЗДЕЛ 1.

ТЕХНИЧЕСКИЕ НАУКИ

1.1. ИНФОРМАТИКА, ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И УПРАВЛЕНИЕ

СРАВНЕНИЕ ТОЧНОСТИ КРАТКОСРОЧНОГО И ДОЛГОСРОЧНОГО ПРОГНОЗИРОВАНИЯ СПРОСА НА ТРАНСПОРТНЫЕ УСЛУГИ С ИСПОЛЬЗОВАНИЕМ ИНТЕЛЛЕКТУАЛЬНЫХ МЕТОДОВ

Бокарев Дмитрий Вячеславович

аспирант,

Российская академия народного хозяйства

и государственной службы

при Президенте Российской Федерации,

РФ, г. Москва

COMPARISON OF THE ACCURACY OF SHORT-TERM AND LONG-TERM FORECASTING OF DEMAND FOR TRANSPORTATION SERVICES USING INTELLIGENT METHODS

Bokarev Dmitry Vyacheslavovich

Graduate student,

Russian Academy of National Economy

and Public Administration

under the President of the Russian Federation,

Russia, Moscow

Аннотация. В статье рассматривается вопрос зависимости точности прогнозирования спроса на автомобильные грузоперевозки от длительности временного горизонта. На основе данных цифровой платформы

за период 2024–2025 гг. проведено сравнение производительности четырёх моделей на недельном, месячном и квартальном интервалах. Выявлены факторы, обуславливающие деградацию производительности и предложены рекомендации по выбору горизонта прогнозирования с учетом специфики решаемых задач.

Abstract. The article examines the dependency of the accuracy of demand forecasting for road freight transportation on the length of the time horizon. Based on data from a digital platform for the 2024–2025, a comparison of the performance of four models was conducted across weekly, monthly, and quarterly intervals. Factors contributing to performance degradation were identified, and recommendations for selecting the forecasting horizon were proposed, taking into account the specifics of business tasks.

Ключевые слова: прогнозирование спроса, транспортные услуги, временной горизонт, гибридная модель, SARIMA, XGBoost, грузоперевозки.

Keywords: demand forecasting, transportation services, time horizon, hybrid model, SARIMA, XGBoost, freight transportation.

Спрос на транспортные услуги является одним из главных экономических показателей для операторов логистики и платформ по осуществлению грузоперевозок и, как и большинство рыночных индикаторов, носит динамичный и нестационарный характер [1]; способность выявлять его будущие значения формирует конкурентное преимущество, позволяя оптимизировать распределение подвижного состава, планировать загрузку ресурсов, корректировать тарифную политику и снижать операционные издержки. В литературе для прогнозирования спроса в транспортной отрасли традиционно применяются как классические методы анализа временных рядов (ARIMA, SARIMA), так и интеллектуальные алгоритмы машинного обучения и их комбинации [2, 3, 4, 5]. Например, в исследовании по железнодорожным грузовым перевозкам показано практическое преимущество ARIMA для годичных прогнозов в прикладном контексте KTZ [4]. В исследовании же спроса на автомобильные перевозки в сервисах совместной мобильности было показано, что нейросетевая модель в общем случае обеспечивает более высокую точность краткосрочного прогноза по сравнению с ARIMAX и регрессионными подходами, снижая индикатор RMSE на 15–25% [5]. Между тем, вопрос зависимости точности прогнозов от временного горизонта остаётся недостаточно изученным. В связи с этим в настоящей статье мы сравниваем производительность четырёх моделей прогнозирования спроса на автомобильные грузоперевозки и услуги переезда на

краткосрочном (неделя), среднесрочном (месяц) и долгосрочном (квартал) горизонтах.

Эмпирическую базу исследования составили данные цифровой платформы грузоперевозок за период январь 2024 - декабрь 2025 с ежедневной частотой наблюдений. Временной ряд подвергался предварительной обработке: выбросы идентифицировались методом межквартильного размаха и заменялись линейной интерполяцией, пропущенные значения восполнялись скользящим средним с окном в 7 дней.

Для моделирования применялись четыре модели:

- SARIMA(1,1,1)(1,1,1)₇ с недельной сезонностью;
- XGBoost с признаками временных лагов, скользящих средних и календарных индикаторов;
- Random Forest с аналогичным набором предикторов;
- гибридная модель SARIMA-XGBoost, где первый компонент захватывает автокорреляционную структуру, второй – моделирует остатки.

Обучение проводилось на выборке январь 2024 – сентябрь 2025, тестирование – на данных октябрь–декабрь 2025. Для каждого горизонта прогнозирования вычислялась средняя абсолютная процентная ошибка как индикатор точности. Итоговые результаты сравнительного анализа представлены в таблице ниже (табл. 1).

Таблица 1.

Средняя абсолютная процентная ошибка (MAPE, %) прогнозов на различных временных горизонтах

Модель	Неделя	Месяц	Квартал
SARIMA	5.2	8.4	12.8
XGBoost	4.1	5.9	9.3
Random Forest	4.5	6.2	10.1
SARIMA-XGBoost	3.6	5.2	8.7

Заметно, что производительность всех моделей последовательно снижается при увеличении временного горизонта. На недельном горизонте гибридная модель обеспечивает MAPE 3.6%, превосходя изолированные подходы на 30-45%. XGBoost демонстрирует вторую по точности производительность (4.1%), Random Forest занимает промежуточное положение (4.5%), тогда как SARIMA уступает алгоритмическим методам (5.2%).

Переход к месячному горизонту сопровождается закономерным ростом ошибок: гибридная модель сохраняет лидерство с MAPE 5.2%, однако разрыв с XGBoost (5.9%) сокращается.

На квартальном горизонте деградация точности становится еще более выраженной: гибридная модель достигает MAPE 8.7%, XGBoost – 9.3%, Random Forest – 10.1%, SARIMA – 12.8%.

Ухудшение точности при удлинении горизонта возможно объяснить несколькими факторами. Первый – накопление ошибок предсказания: многошаговое прогнозирование использует собственные прогнозы предыдущих периодов в качестве входных данных, что приводит к распространению и усилению погрешностей. Второй – затухание автокорреляционных связей: влияние исторических значений спроса на текущие показатели ослабевает во времени, снижая информативность лаговых переменных. Последний фактор связан с возрастанием неопределенности внешних условий: структурные сдвиги в отрасли накапливаются на длительных интервалах, создавая, тем самым, непредсказуемую вариацию спроса.

Примечательно, что гибридная модель показывает меньшую деградацию производительности при переходе от недельного к квартальному горизонту (рост MAPE на 5.1 п.п.) по сравнению с изолированной SARIMA (рост на 7.6 п.п.), что, в общем случае, указывает на повышенную робастность комбинированного подхода к удлинению горизонта предсказания.

Исходя из выявленного, мы можем утверждать, что выбор временного горизонта прогнозирования должен определяться спецификой бизнес-задач. Так, краткосрочные прогнозы (неделя) обеспечивают минимальную ошибку и пригодны для оперативного управления: распределение заказов между водителями, формирование сменных графиков, корректировка тарифов в условиях изменяющегося спроса. Среднесрочные прогнозы (месяц) балансируют между точностью и практической применимостью, поддерживая решения по планированию загрузки подвижного состава, закупке топлива, организации технического обслуживания. Долгосрочные прогнозы (квартал и более) характеризуются возросшей погрешностью, однако остаются полезными для стратегического планирования: расширение автопарка, открытие новых направлений, заключение долгосрочных контрактов с корпоративными клиентами. При выборе модели операторам транспортных платформ рекомендуется применять гибридные подходы для минимизации ошибок на всех горизонтах, особенно при необходимости квартального планирования, где преимущество комбинированных методов проявляется наиболее отчетливо.

Итак, полученные результаты подтверждают, что точность прогнозирования спроса на транспортные услуги систематически снижается с увеличением временного горизонта, при этом гибридная модель

SARIMA-XGBoost обеспечивает оптимальный баланс между производительностью и робастностью на всех рассмотренных интервалах.

Список литературы:

1. Николин В.И., Витвицкий Е.Е., Мочалин С.М. Грузовые автомобильные перевозки: монография / В.И. Николин, Е.Е. Витвицкий, С.М. Мочалин. – 2-е изд. – Омск : Вариант-Сибирь, 2004. – 480 с.
2. Маловецкая, Е.В. Возможности применения моделей ARIMA при построении прогнозных значений вагонопотоков / Е.В. Маловецкая, А.К. Мозалевская // Т-Comm: Телекоммуникации и транспорт. – 2023. – Т. 17, № 1. – С. 33–41. – DOI 10.36724/2072-8735-2023-17-1-33-41.
3. Sultanbek M., Adilova N., Śladkowski A., Karibayev A. Forecasting the demand for railway freight transportation in Kazakhstan: A case study // Transportation Research Interdisciplinary Perspectives. – 2024. – Vol. 23. – Art. 101028. – DOI: 10.1016/j.trip.2024.101028.
4. Dong H., Jia L., Sun X., Li C., Qin Y. Road traffic flow prediction with a time-oriented ARIMA model // Proceedings of the Fifth International Joint Conference on INC, IMS and IDC. – Seoul, 2009. – P. 1649–1652. – DOI: 10.1109/NCM.2009.224.
5. Chen L., Thakuriah P., Ampountolas K. Short-term prediction of demand for ride-hailing services: a deep learning approach // Journal of Big Data Analytics in Transportation. – 2021. – Vol. 3. – No. 2. – P. 175–195. – DOI: 10.1007/s42421-021-00041-4.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ И 1С: ПОМОЩНИК ИЛИ ЗАМЕНА СПЕЦИАЛИСТАМ?

Петрова Мария Владимировна

ведущий специалист

*компании Производственная безопасность и экология,
РФ, г. Москва*

Слепушкина Анастасия Александровна

заместитель генерального директора

*Производственная безопасность и экология
по методологическим вопросам,
РФ, г. Москва*

Аннотация. Мы стоим на пороге новой эры, где искусственный интеллект (ИИ) становится не просто инструментом для работы, а активным участником в любой сфере. В статье рассмотрим актуальность замены специалистов в сфере 1С на ИИ.

Ключевые слова: 1С, искусственный интеллект, Производственная безопасность и экология

Введение

Технологический прогресс неумолимо движется вперед, и сегодня мы стоим на пороге новой эры, где искусственный интеллект (ИИ) становится не просто инструментом для работы, а активным участником в любой сфере.

Один из самых обсуждаемых вопросов касается его роли в таких областях, как бухгалтерия и управление предприятием на платформе 1С.

Можно ли полностью заменить человека в этих процессах?

Давайте разберемся.

Что такое искусственный интеллект?

Искусственный интеллект – это область компьютерных наук, целью которой является создание систем, способных выполнять задачи, требующие для человека элементов интеллекта: обучения, рассуждения, решения проблем, понимания естественного языка и т.д.

Основные подвиды ИИ:

Машинальное обучение (Machine Learning) - алгоритмы, которые учатся на данных без явного программирования.

Глубокое обучение (Deep Learning) - подразделение машинного обучения, использующее нейронные сети.

Естественно-языковая обработка (NLP) - технология, позволяющая системе понимать, интерпретировать и генерировать текст на человеческом языке.

История применения ИИ в 1С

1С - не просто платформа, а экосистема для создания деловых приложений, таких как ERP, CRM, бухгалтерские программы и многие другие. С появлением первых версий 1С еще в 90-х годах началось активное развитие российского ПО для автоматизации бизнеса.

На сегодняшний день ИИ постепенно интегрируется в 1С и уже достигло некоторых успехов:

Этапы внедрения ИИ в 1С:

Автоматизация рутинных расчетов – в 1С начали внедрение искусственного интеллекта с упрощения повседневных операций: бухгалтеры и операторы перестали вручную вводить данные, передавая эту задачу автоматизированным скриптам и интегрированным ИИ-модулям. Это позволило сократить время на обработку первичной документации, снизить количество ошибок и освободить сотрудников для более сложных задач.

Аналитика и прогнозирование - на следующем этапе в 1С стали внедрять специализированные модули на базе ИИ, предназначенные для анализа больших объемов финансовых, складских и управленческих данных.

На примере 1С:Прогнозирование продаж [5] можно увидеть, что такие модули позволяют не просто собирать отчёты, но и выявлять скрытые закономерности, прогнозировать спрос, оптимизировать запасы, а также предлагать рекомендации по улучшению бизнес-процессов.

Интеллектуальная обработка документов – есть мобильные приложения, которые позволяют через телефон проводить сканирование документов в 1С и благодаря автоматическому распознаванию текста вводит первичную документацию за вас [6].

Голосовые помощники и чат боты – уже внедрено в «1С:Распознавание первичных документов» (1С:РПД) поддерживает работу с основными первичными документами: счетами, накладными (ТОРГ-12), актами, счета-фактурами, УПД, УКД и кассовыми чеками. [7]

Генерация кода - современные ИИ-инструменты, обученные на массивах типовых и нестандартных решениях для платформы 1С, способны автоматически генерировать фрагменты кода на языке 1С:Enterprise или даже целые модули конфигурации на основе описания требований

на естественном языке. Также можно использовать ИИ для написания ТЗ или плана по решению задач в помощь программисту.

Компания «Производственная безопасность и экология» уже применяет и реализовывает связи между ИИ и 1С

Для платформы 1С с помощью решения «EHS: Комплексная производственная безопасность КОРП» был реализован блок Видеомониторинг с функцией распознавания средств индивидуальной защиты (СИЗ) на основе технологий искусственного интеллекта.

В режиме реального времени ИИ обрабатывает информацию с камер видеонаблюдения, отслеживая события исходя из поставленных задач видеоконтроля.

Например: контроль опасной зоны, контроль средств индивидуальной защиты, контроль средств индивидуальной защиты по месту работ.

Так же ИИ передает сведения о нарушениях соответствующим лицам согласно заданным сценариям работы и формировать перечень мероприятий для устранения аналогичных нарушений. [1, с. 3],[2, с. 4]

Такая возможность позволяет руководителям, специалистам по охране труда и промышленной безопасности повысить эффективность контроля опасной зоны, контроля средств индивидуальной защиты, без влияния человеческого фактора

Компания ПБЭ разрабатывает ИИ-ассистента для конфигурации 1С: Производственная безопасность. Комплексная.

И тут возникает вопрос, а что такое ИИ-ассистент и для чего он нужен?

ИИ-ассистент - программный продукт, который имитирует поведение человека, обрабатывая запросы пользователя.

В контексте 1С, это могут быть:

Виртуальные помощники - отвечают на вопросы по 1С в чате или голосовом режиме.

Автоматические консультанты - помогают новичкам разбираться в настройках 1С.

Инструменты для обучения - ИИ объясняет сложные концепции простым языком.

Возможна ли полная замена человека искусственным интеллектом в 1С?

На первый взгляд да, но, если копнуть глубже - нет.

Давайте разберем:

Преимущества ИИ по сравнению с человеком:

Точность - ИИ не ошибается в расчетах, если данные правильно заданы.

Скорость - анализ данных сотен тысяч записей за секунды.

24/7 работоспособность - система не устает и не требует перерывов.

Почему ИИ - не замена, а помощник:

Отсутствие интуиции и здравого смысла - ИИ не понимает, например, бизнес-ситуации в компании.

Нет человеческого опыта - адаптация под уникальные условия требует профессионального подхода.

Этические и юридические ограничения - заключаются в необходимости соблюдения прав человека, конфиденциальности, объективности над решениями, затрагивающими жизнь и свободы людей.

Творческий и стратегический аспекты - ИИ может анализировать большие объёмы данных, чтобы создавать идеи и разрабатывать эффективные стратегии, но ему не хватает человеческого воображения, интуиции, морального понимания и истинной новаторской способности.

Заключение

Таким образом можно прийти к выводу, что искусственный интеллект – это не враг для человека, а скорее возможности, которые делают его работу эффективнее и легче.

Он способен заменить рутину, но не заменить специалиста.

Искусственным интеллектом нужно учиться управлять и развивать свои навыки: интуиция, стратегическое мышление, этика и творчество, которые не доступны ИИ.

В будущем, ИС будет только глубже интегрирован с искусственным интеллектом, но настоящие мастера своего дела - всегда будут нужны для постановки задач, проверки результатов и принятия окончательных решений.

Список литературы:

1. Официальный сайт разработчиков ИС: <https://www.1c.ru>
2. Сайт о поддержке программных продуктов фирмы ИС: <https://portal.1c.ru>
3. Сайт для создания и поиска статей: <https://dzen.ru>
4. Сайт компании «Производственная безопасность и экология» <https://www.1c-prombez.ru>
5. Подробнее о Прогнозе продаж в программах ИС <https://portal.1c.ru/applications/1C-Forecast-sales>
6. ИС: Сканер <https://ocr.1c.ai>
7. Информация о распознавании первичных документов <https://portal.1c.ru/applications/1C-Document-Recognition>

1.2. ЭНЕРГЕТИКА

ПРИМЕНЕНИЕ ГРАФОВЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АНАЛИЗА И ОПТИМИЗАЦИИ ПОТОКОРАСПРЕДЕЛЕНИЯ В РАСПРЕДЕЛИТЕЛЬНЫХ СЕТЯХ: ПОСТАНОВКА ЗАДАЧИ В КОНТЕКСТЕ РОССИЙСКОЙ ЭНЕРГЕТИКИ И БОЛЬШИХ ДАННЫХ

Королев Владислав Игоревич

аспирант,

Белгородский государственный

национальный исследовательский университет,

РФ, г. Белгород

Аннотация. В статье рассматривается проблема адаптации традиционных методов расчёта режимов распределительных электрических сетей к условиям роста сложности и цифровизации энергосистемы России. Актуальность исследования обусловлена появлением новых крупных потребителей, таких как центры обработки данных (ЦОД), и необходимостью интеграции больших объёмов данных с различных датчиков и систем мониторинга в реальном времени. Проведён обзор современных методов анализа больших данных, применяемых в электроэнергетике, включая потоковую аналитику, машинное обучение и графовые нейронные сети (GNN). Выявлены ключевые недостатки существующих подходов: низкая физическая адекватность классических методов машинного обучения и вычислительная сложность современных GNN, неприспособленных для динамически меняющейся топологии сетей. На основе анализа сформулирована постановочная задача научного исследования: разработка гибридной архитектуры графовых нейронных сетей, учитывающей физические законы электроэнергетики и адаптированной к особенностям российской инфраструктуры, включая требования информационной безопасности и цифрового суверенитета. Предложена концептуальная модель такой платформы, интегрирующая разнородные данные для задач оперативного и долгосрочного анализа.

Abstract. The article addresses the problem of adapting traditional methods for calculating the operating conditions of distribution electrical networks to the increasing complexity and digitalization of Russia's energy system. The relevance of the research is driven by the emergence of new large

consumers, such as data centers, and the need to integrate large volumes of data from various sensors and real-time monitoring systems. A review of modern big data analysis methods used in the electric power industry is conducted, including stream analytics, machine learning, and graph neural networks (GNNs). Key shortcomings of existing approaches are identified: the low physical adequacy of classical machine learning methods and the computational complexity of modern GNNs, which are not adapted to dynamically changing network topologies. Based on the analysis, a research problem is formulated: the development of a hybrid graph neural network architecture that considers the physical laws of power engineering and is adapted to the specifics of Russian infrastructure, including information security requirements and digital sovereignty. A conceptual model of such a platform, integrating heterogeneous data for operational and long-term analysis tasks, is proposed.

Ключевые слова: распределённая энергосистема, большие данные, графовые нейронные сети, центры обработки данных, потокораспределение, цифровой суверенитет, машинное обучение, гибридная архитектура.

Keywords: distributed power system, big data, graph neural networks, data centers, power flow, digital sovereignty, machine learning, hybrid architecture.

Введение. Современная электроэнергетическая инфраструктура России находится в процессе глубокой трансформации, движимой двумя взаимосвязанными трендами. Во-первых, это стремительный рост энергопотребления со стороны новых цифровых отраслей. Центры обработки данных (ЦОД), являющиеся фундаментом цифровой экономики и искусственного интеллекта, превратились в одних из крупнейших потребителей электроэнергии. Только в 2024 году их глобальное энергопотребление составило около 415 ТВт·ч, а к 2030 году прогнозируется его удвоение. В России число коммерческих ЦОД достигло 255 с совокупной потребностью в мощности 1,0–1,7 ГВт, что создаёт высокую, часто неравномерную, нагрузку на распределительные сети. Энергетическая плотность стоек для задач ИИ (до 120 кВт) кардинально превышает показатели традиционных ЦОД, требуя качественно иной сетевой инфраструктуры.[2]

Во-вторых, в рамках национального проекта «Экономика данных и цифровая трансформация государства» происходит активная цифровизация критически важных отраслей, включая ТЭК. Объём рынка больших данных и ИИ в России к 2025 году может достичь 520 млрд

рублей, а для их обработки формируются гибридные архитектуры, сочетающие локальное хранение чувствительных данных и облачные вычисления.[6] Это порождает огромные массивы разнородных данных от систем SCADA, IoT-датчиков, интеллектуальных систем учёта и геоинформационных систем.

Таким образом, перед распределёнными электроэнергетическими системами встаёт сложная задача: обеспечить надёжное и экономичное электроснабжение новых потребителей в условиях, когда для управления сетями становится доступен огромный объём данных в реальном времени. Ключевой проблемой является прогнозирование и анализ потокораспределения – основы для принятия решений по управлению режимами, развитию сети и предотвращению аварий. Традиционные итерационные методы (например, Ньютона-Рафсона), хотя и обеспечивают точность, становятся недостаточно гибкими и быстрыми для работы в динамичной среде с постоянно меняющейся конфигурацией и большими данными. Это обуславливает необходимость поиска новых, основанных на данных (data-driven) подходов, адаптированных к российским реалиям.

Обзор методов анализа больших данных для задач электроэнергетики

Для решения задач анализа сложных систем, таких как распределительные сети, применяется спектр методов Big Data-аналитики. Каждый из них имеет свою область эффективного применения и ограничения, что отражено в Таблице 1.

Таблица 1.

Сравнительный анализ методов больших данных для задач анализа электроэнергетических систем

Категория методов	Примеры технологий / алгоритмов	Преимущества для задач энергетики	Недостатки и ограничения
Потоковая аналитика (Stream Processing)	Apache Kafka, Apache Flink, Apache Storm.	Сверхнизкая задержка, обработка данных в реальном времени. Идеально для мониторинга текущего состояния, обнаружения аномалий и оперативного реагирования .	Ориентирована на поверхностный анализ «здесь и сейчас». Не приспособлена для глубокого прогнозного моделирования и учёта топологии сети. [4]

Категория методов	Примеры технологий / алгоритмов	Преимущества для задач энергетики	Недостатки и ограничения
Классическое машинное обучение и глубокое обучение	Регрессионные модели, метод опорных векторов (SVM), ансамбли (Random Forest, Gradient Boosting), рекуррентные нейронные сети (RNN, LSTM).	Высокая точность в задачах прогнозирования временных рядов (нагрузка, генерация). Способность выявлять сложные нелинейные зависимости в исторических данных .	Модели работают с данными как с «плоскими» временными рядами, игнорируя топологию и физические связи в сети. Результаты могут быть физически некорректными («чёрный ящик»).[3]
Графовые аналитические модели и нейронные сети (GNN)	Алгоритмы на графах (PageRank, community detection), Graph Convolutional Networks (GCN), Graph Attention Networks (GAT).	Прямое моделирование сетевой структуры. Учёт связей между узлами (подстанциями) и рёбрами (линиями). Высокий потенциал для расчёта потокораспределения, анализа устойчивости и уязвимостей .	Высокая вычислительная сложность для крупных сетей. Большинство архитектур предполагают статическую, неизменяемую топологию графа, что не соответствует реальности (ремонт, переключения). Катастрофическая забывчивость при изменении графа.[4]
Гибридные (Physics-Informed) и онтологические подходы	Physics-Informed Neural Networks (PINN), семантические онтологии (RDF, OWL), цифровые двойники.	Возможность интеграции фундаментальных физических законов (законы Кирхгофа) в модель данных. Обеспечение физической адекватности прогнозов и устойчивости модели .	Сложность разработки и обучения. Дефицит готовых отраслевых решений и стандартов. Требуют глубоких междисциплинарных знаний.[1]

Как видно из таблицы, наиболее перспективным для непосредственной работы с сетевыми структурами является класс графовых нейронных сетей. GNN способны агрегировать информацию от соседних

узлов, что напрямую соответствует процессам распространения мощности в сети. Однако их прямое применение наталкивается на фундаментальное противоречие: электрическая сеть – это **динамический граф**, чья топология меняется вследствие плановых переключений, ремонтов и аварийных ситуаций. Существующие модели GNN, такие как GCN, плохо обобщают свои знания на графы, структура которых не встречалась при обучении, что ограничивает их практическое применение.

Кроме технологических ограничений, в российском контексте добавляются требования **информационной безопасности и цифрового суверенитета**. Данные о режимах работы энергосистем относятся к критической информационной инфраструктуре (КИИ). Согласно новым требованиям регуляторов (приказ ФСТЭК России №117), необходимы специальные сертифицированные средства защиты и, зачастую, локальное хранение и обработка чувствительных данных. Это стимулирует развитие гибридных архитектур, где обучение моделей происходит на синтетических или обезличенных данных в защищённом облаке, а инференс – на периферии, внутри защищённого периметра компании.

Постановка задачи: концепция гибридной GNN-архитектуры для отечественной распределительной сети

На основе проведённого анализа формулируется постановочная задача исследования: **разработка методики и архитектуры гибридной аналитической платформы на основе графовых нейронных сетей для адаптивного анализа и прогнозирования потокораспределения в распределительных сетях России.**

Ключевые аспекты задачи:

1. **Учёт динамической топологии:** Модель должна быстро адаптироваться к изменениям конфигурации сети (замыкание/размыкание выключателей) без необходимости полного переобучения.

2. **Интеграция физических законов :** В структуру потерь или ограничений GNN должны быть явным образом встроены уравнения электротехники, чтобы гарантировать физическую корректность прогноза.

3. **Соответствие требованиям безопасности:** Архитектура должна допускать работу в гибридном режиме: обучение на синтетических данных, генерируемых на основе реальных, но обезличенных сценариев, и выполнение на защищённом вычислительном контуре энергокомпании.

4. **Масштабируемость и интеграция:** Платформа должна эффективно интегрировать разнородные данные (потокосовые с датчиков, исторические режимные данные, GIS-информацию) и масштабироваться на сети разного размера.

Концептуальная архитектура такой платформы представлена в Таблице 2.

Таблица 2.

Концепция гибридной аналитической платформы на основе GNN

Уровень архитектуры	Технологический стек и методы	Решаемые подзадачи
Слой данных и интеграции	Гибридное хранилище: локальная БД (для чувствительных данных) + Data Lake (для обезличенных/синтетических данных). Apache NiFi/Kafka для потоковой интеграции.	Сбор данных с АСКУЭ, РЗА, РМУ. Генерация синтетических дата-сетов для обучения с учётом российских нормативов и типового оборудования. [6]
Слой графового моделирования	Динамический графовый движок (например, на базе Neo4j или специализированных библиотек). Модуль актуализации топологии в реальном времени.	Преобразование сетевой схемы и текущего состояния коммутационных аппаратов в графовую модель. Учёт изменений топологии как модификаций графа.
Аналитическое ядро (GNN-модели)	Библиотеки глубокого обучения (PyTorch Geometric, DGL). Кастомные слои GNN с физическими ограничениями (PINN). Набор моделей для разных задач: GCN для базового расчёта, GAT для анализа важности узлов, динамические GNN для прогноза.	Обучение на синтетических и исторических данных. Внедрение в функцию потерь компонент, учитывающих нарушения законов Кирхгофа. Разработка механизма «дообучения на лету» при значительном изменении графа.
Слой симуляции и интерфейсов	Веб-интерфейс для диспетчера, API для интеграции с внешними системами (АСУ ТП, системы планирования). Модуль «что-если» анализа (what-if analysis).	Визуализация потокораспределения, выделение узких мест и рискованных участков. Предоставление рекомендаций по оптимальным переключениям для разгрузки сети, питающей ЦОД. [2]

Заключение. В статье проведён анализ современных методов больших данных применительно к актуальной задаче анализа распределённых электроэнергетических систем России. Выявлено, что рост энергоёмких цифровых потребителей (ЦОД) и доступность больших данных создают как вызовы для сетевой инфраструктуры, так и новые возможности для её управления. Существующие методы – от потоковой аналитики до классического машинного обучения – решают частные задачи, но не обеспечивают комплексного, быстрого и физически адекватного анализа сетевой топологии и режимов.

В качестве перспективного направления предложено применение графовых нейронных сетей. Однако для их успешной имплементации необходимо преодолеть ряд фундаментальных и практических ограничений, главные из которых – неспособность стандартных GNN работать с динамически меняющейся топологией и отсутствие гарантий физической корректности их выводов. Сформулирована постановочная задача по разработке гибридной GNN-архитектуры, адаптированной к российским условиям. Ключевыми особенностями предлагаемого подхода являются: интеграция физических законов в модель, механизмы адаптации к изменениям конфигурации сети, а также соответствие требованиям информационной безопасности через использование гибридных схем обработки данных. Реализация данной концепции позволит создать инструмент для повышения надёжности, эффективности и гибкости распределительных сетей в условиях их цифровой трансформации и роста нагрузки.

Список литературы:

1. Design methodology of intelligent autonomous distributed hybrid power complexes with renewable energy sources // International Journal of Hydrogen Energy. 2023.
2. Трифонова В.К. Центры обработки данных становятся одними из главных энергопотребителей // NG Энергия. 2026. 22 янв.
3. Data-informed hybrid renewable system design based on building energy demand prediction: A machine learning and deep learning approach // Journal of Energy Storage. 2025. [Citation:3]
4. Comprehensive Review of Hybrid Energy Systems: Challenges, Applications, and Optimization Strategies // Energies. 2025. Vol. 18, Iss. 10.
5. Шесть глобальных тенденций в области ядерной энергетики, о которых стоит знать // МАГАТЭ. 2025. 19 нояб.
6. Большие данные пошли в рост // Коммерсантъ. 2025.
7. Kipf T.N., Welling M. Semi-Supervised Classification with Graph Convolutional Networks // International Conference on Learning Representations (ICLR). 2017.
8. Battaglia P.W., Hamrick J.B., Bapst V., et al. Relational inductive biases, deep learning, and graph networks // arXiv preprint arXiv:1806.01261. 2018.
9. Raissi M., Perdikaris P., Karniadakis G.E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // Journal of Computational Physics. 2019. Vol. 378. P. 686–707.

10. Крюков К.В., Сироткин А.С. Применение методов машинного обучения для прогнозирования нагрузок в электроэнергетических системах // Известия РАН. Энергетика. 2022. № 5. С. 88–101.
11. Петров А.А., Смирнов И.В. Цифровые двойники распределительных электрических сетей: архитектура и методы построения // Энергетик. 2023. № 7. С. 45–51.
12. Baran M.E., Wu F.F. Network reconfiguration in distribution systems for loss reduction and load balancing // IEEE Transactions on Power Delivery. 1989. Vol. 4, Iss. 2. P. 1401–1407.
13. Отраслевая цифровизация 2024: ТЭК. Аналитический отчёт Ассоциации «Большие данные». М., 2024.
14. Рекомендации по построению систем аналитики больших данных для объектов критической информационной инфраструктуры. ФСТЭК России, 2025.
15. Donon B., Clément R., Donnot B., et al. Neural Networks for Power Flow: Graph Neural Solver // Electric Power Systems Research. 2020. Vol. 189. 106547.

ДЛЯ ЗАМЕТОК

**НАУЧНЫЙ ФОРУМ:
ТЕХНИЧЕСКИЕ И ФИЗИКО-МАТЕМАТИЧЕСКИЕ НАУКИ**

*Сборник статей по материалам XIII международной
научно-практической конференции*

№ 2 (93)
Февраль 2026 г.

В авторской редакции

Подписано в печать 05.02.2026. Формат бумаги 60x84/16.
Бумага офсет №1. Гарнитура Times. Печать цифровая.
Усл. печ. л. 1,38. Тираж 550 экз.

Издательство «МЦНО»
123098, г. Москва, ул. Маршала Василевского, дом 5, корпус 1, к. 74
E-mail: tech@nauchforum.ru

Отпечатано в полном соответствии с качеством предоставленного
оригинал-макета в типографии «Allprint»
630004, г. Новосибирск, Вокзальная магистраль, 1



**НАУЧНЫЙ
ФОРУМ**
nauchforum.ru