

УДК 004.85:711.4

**ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ
ПРОГНОЗИРОВАНИЯ НАГРУЗОК НА ЭНЕРГОСЕТИ И
ТРАНСПОРТНЫЕ ПОТОКИ В УСЛОВИЯХ ГОРОДА**

**APPLICATION OF MACHINE LEARNING FOR FORECASTING
LOADS ON POWER GRIDS AND TRAFFIC FLOWS IN URBAN
CONDITIONS**

Т.Ю. Казанцев, студентка I курса гр. ПИБ-251.3

А.В. Ионина, к.т.н., доцент кафедры ИТиЭД,

Филиал Федерального Государственного бюджетного образовательного
учреждения высшего образования «Кузбасский государственный

технический университет имени Т.Ф. Горбачева»

в г. Новокузнецке, г. Новокузнецк

Аннотация: в статье рассматривается проблема прогнозирования нагрузок на критически важные инфраструктурные системы современного города – энергетические сети и транспортные магистрали. Анализируются традиционные и современные подходы к прогнозированию, обосновывается преимущество методов машинного обучения. Представлен обзор актуальных российских исследований и разработок в данной области, систематизированы данные о точности различных моделей. Предложена классификация факторов, влияющих на прогнозируемые показатели, и описана обобщенная архитектура интеллектуальной системы прогнозирования. Делается вывод о необходимости интеграции таких систем в концепцию «умного города» для повышения эффективности управления ресурсами и обеспечения устойчивого развития урбанизированных территорий.

Ключевые слова: машинное обучение, нейронные сети, прогнозирование, энергопотребление, транспортные потоки, умный город, большие данные, интеллектуальные транспортные системы.

Abstract: the article deals with the problem of forecasting loads on critical infrastructure systems of a modern city – power grids and transport routes. Traditional and modern approaches to forecasting are analyzed, and the advantage of machine learning methods is substantiated. A review of current Russian research and development in this area is presented, data on the accuracy of various models are systematized. A classification of factors influencing the predicted indicators is proposed and a generalized architecture of an intelligent forecasting system is described. The conclusion is made about the need to integrate such systems into the concept of a «smart city» to improve the

efficiency of resource management and ensure sustainable development of urbanized territories.

Keywords: machine learning, neural networks, forecasting, energy consumption, traffic flows, smart city, big data, intelligent transport systems.

Урбанизация является одной из определяющих тенденций развития современного общества. По данным ООН, к 2050 году доля городского населения планеты достигнет 68 %. Это неизбежно ведет к колоссальному росту нагрузок на инфраструктуру городов. Две наиболее чувствительные сферы – энергоснабжение и транспорт. Перебои в электроснабжении парализуют работу предприятий и социальных учреждений, а транспортные заторы ежегодно обходятся экономике мегаполисов в миллиарды рублей из-за потерь времени, перерасхода топлива и ухудшения экологической обстановки [1].

Традиционные методы прогнозирования, такие как регрессионный анализ или экспертные оценки, часто оказываются несостоятельными перед лицом нелинейности и многомерности современных городских процессов. Они не способны эффективно обрабатывать потоки данных в реальном времени и адаптироваться к быстро меняющимся условиям [2]. Целью данной работы является комплексный анализ потенциала методов машинного обучения для решения задач прогнозирования нагрузок на энергосети и транспортные потоки в условиях города, а также систематизация опыта российских научных коллективов в этой области.

Для понимания преимущества машинного обучения необходимо сравнить его с классическими подходами. В таблице 1 представлен сравнительный анализ основных методов прогнозирования.

Таблица 1 – Сравнительный анализ методов прогнозирования нагрузок на городские системы

Характеристика	Классические статистические методы (ARIMA, экспоненциальное сглаживание)	Методы машинного обучения (нейронные сети, градиентный бустинг)
Тип зависимостей	Линейные, стационарные	Нелинейные, сложные, нестационарные
Объем данных	Требуют относительно небольших исторических выборок	Эффективны при работе с большими данными (Big Data)
Адаптивность	Низкая, требуют ручной перенастройки при изменении процесса	Высокая, способны к дообучению на новых данных
Учет внешних факторов	Ограничен (макс. 1–2 фактора)	Множественный (погода, события, ДТП, праздники и др.)

Точность прогноза	Средняя, падает при увеличении горизонта прогноза	Высокая, особенно для краткосрочных прогнозов
Пример точности	Ошибка прогноза электропотребления ~6–7 % [3]	Ошибка прогноза электропотребления ~1,6–2 % [3]

Как видно из таблицы 1, методы машинного обучения превосходят классические практически по всем ключевым параметрам, что делает их незаменимым инструментом для управления сложными системами современного города.

Качество прогноза напрямую зависит от того, какие данные анализирует модель. Факторы, влияющие на энергопотребление и интенсивность трафика, можно разделить на несколько групп. Для энергетических систем ключевыми факторами являются временные параметры (время суток, день недели, сезон, праздничные дни), метеорологические условия (температура воздуха, облачность, влажность, сила ветра), а также социально-экономические показатели (структура потребления, тарифная политика, проведение массовых мероприятий) [4]. Для транспортных потоков определяющими факторами выступают временные характеристики (часы пик, выходные, сезон отпусков), дорожные условия (пропускная способность магистралей, наличие ремонтных работ, качество покрытия), событийные факторы (ДТП, массовые мероприятия, перекрытия улиц) и погодные условия (снегопад, дождь, гололед, снижающие скорость потока) [5].

Современные модели машинного обучения способны учитывать все эти факторы одновременно, присваивая им различные веса и выявляя сложные перекрестные влияния. Например, влияние температуры на энергопотребление будет разным в рабочий и выходной день [4].

В последние годы в России наблюдается значительный прогресс в разработке и внедрении интеллектуальных систем прогнозирования. Наиболее показательные примеры систематизированы в таблице 2.

Таблица 2 – Российские разработки в области прогнозирования нагрузок

Разработчик	Область применения	Используемые методы	Результат
ПНИПУ (г. Пермь)	Прогнозирование электропотребления насосных станций водоснабжения	Алгоритмы машинного обучения на основе исторических данных с учетом типа дня	Снижение погрешности прогноза с 6,2 % до 1,67 % (в 3,7 раза). Экономия 160 тыс. руб./год на одной станции [3]
ЮУрГУ (г. Челябинск)	Прогнозирование в коммунально-	Нейросетевые технологии, учет	Повышение стабильности

	бытовых сетях, выявление несимметрии фаз	коэффициента неопределенности	сетей, возможность оптимизации загрузки фаз, предотвращение аварий [4]
Журнал «Промышленная кибернетика»	Управление электропотреблением в энергосистемах	Генетические алгоритмы для оптимизации архитектуры нейросетей	Автоматический подбор оптимальной архитектуры нейросети, максимизация точности прогноза [6]
ДГТУ (г. Ростов-на-Дону)	Прогнозирование интенсивности городского трафика	Анализ исторических данных «часов пик» + адаптация к внештатным ситуациям	Точность прогноза загруженности до 94 % (против 70–75 % у существующих моделей) [7, 8]
Научная платформа SciNetwork	Прогнозирование транспортной загруженности с учетом погоды	Гибридная модель ARIMA + LSTM	Успешное моделирование нелинейных зависимостей; учет погодных факторов, повышающих нагрузку на 20–30 % [9]
УрГЭУ (г. Екатеринбург)	Транспортно-логистические системы «умных городов»	Линейная регрессия, LightGBM	Определение оптимальных моделей для разных задач [2]

Анализ таблицы 2 показывает, что российские ученые успешно решают задачи высокой сложности, а внедрение их разработок дает измеримый экономический и социальный эффект.

На основе анализа рассмотренных работ можно выделить ключевые модули, входящие в состав интеллектуальной системы прогнозирования нагрузок. Первым является модуль сбора и агрегации данных, который получает информацию из разнородных источников: датчики интернета вещей на линиях электропередач и трансформаторных подстанциях, детекторы транспорта (индукционные петли, видеокамеры, GPS-трекеры), метеорологические службы, городские сервисы (план ремонтных работ, афиша мероприятий, данные о ДТП), а также календарь праздничных и выходных дней. Второй модуль – предобработки данных – осуществляет очистку данных от шумов и выбросов, восстановление пропущенных значений, нормализацию и приведение данных к единому формату,

пригодному для анализа [1]. Третий модуль – моделирования – является ядром системы и содержит обученную модель машинного обучения (например, нейронную сеть LSTM, градиентный бустинг CatBoost или гибридную модель), которая анализирует подготовленные данные и формирует прогноз [6]. Четвертый модуль – верификации и коррекции – обеспечивает оценку точности прогноза путем сравнения с фактическими данными, поступающими с задержкой, и при необходимости инициирует процесс дообучения модели. Пятый модуль – визуализации и принятия решений – представляет прогнозы в удобном для диспетчера виде (графики, тепловые карты, рекомендации). Для транспортного потока это может быть прогноз заторов и рекомендации по настройке светофоров, для энергетиков – прогноз пиковых нагрузок и рекомендации по резервированию мощностей [5]. Такая модульная архитектура является универсальной и может быть адаптирована как для управления энергосетями, так и для транспортной логистики.

Несмотря на очевидные преимущества, внедрение систем прогнозирования на основе машинного обучения сталкивается с рядом проблем. К основным барьерам относятся: недостаточное развитие инфраструктуры сбора данных (нехватка датчиков и детекторов), разрозненность ведомственных информационных систем, сложность интеграции разнородных данных, а также дефицит квалифицированных кадров, способных разрабатывать и сопровождать такие системы [1]. Перспективы развития связаны с созданием единых городских платформ данных, стандартизацией протоколов обмена информацией, развитием технологий интернета вещей и повышением доступности вычислительных ресурсов для обработки больших данных [2].

Проведенный анализ российских научных исследований подтверждает, что методы машинного обучения являются наиболее перспективным инструментом для прогнозирования нагрузок на энергетическую и транспортную инфраструктуру современных городов. Интеллектуальные системы, основанные на нейросетях и гибридных алгоритмах, демонстрируют значительно более высокую точность по сравнению с традиционными подходами (снижение ошибки прогноза в разы), способны работать в реальном времени и учитывать широкий спектр влияющих факторов – от погоды до городских событий. Внедрение подобных разработок, уже успешно протестированных в Перми, Челябинске, Ростове-на-Дону, позволяет не только предотвращать аварийные ситуации и оптимизировать использование ресурсов, но и получать прямой экономический эффект. Дальнейшее развитие данного направления должно быть связано с созданием единых городских платформ сбора данных и стандартизацией подходов к построению прогнозных моделей, что станет важным шагом на пути к созданию настоящего «умных» и устойчивых городов будущего.

Список литературы

1. Савин Г. В. Определение модели развития транспортно-логистической системы умного города / Г. В. Савин // Известия Юго-Западного государственного университета. Серия: Экономика. Социология. Менеджмент. – 2025. – Т. 15, № 5. – С. 171–179. – URL: <https://ecsocmenus.elpub.ru/jour/article/view/1220/0> (дата обращения: 26.02.2026).
2. Разработка ученых ПНИПУ повысит точность прогноза электропотребления насосных станций в 3,7 раза // [CNews.ru](https://cnews.ru): сайт. – 2025. – URL: https://www.cnews.ru/news/line/2025-12-16_razrabotka_uchenyh_pnipu (дата обращения: 26.02.2026).
3. Нейросеть обеспечит стабильное электроснабжение жилых районов // Южно-Уральский государственный университет: сайт. – 2023. – URL: <https://www.susu.ru/ru/news/2023/05/12/neyroset-obespechit-stabilnoe-elektrosnabzhenie-zhilyh-rayonov> (дата обращения: 26.02.2026).
4. Полуянович Н. К. Нейросетевые технологии прогнозирования и управления электропотреблением в энергетических системах с использованием генетического метода / Н. К. Полуянович, О. В. Качелаев, М. Н. Дубяго, Т. Х. Фалькон // Промышленная кибернетика. – 2025. – Т. 3, № 1. – URL: <https://indcyb.ru/journal/article/view/85> (дата обращения: 26.02.2026).
5. Ученые создали дорожный «оракул», предсказывающий пробки с точностью в 94 % // За рулем: сайт. – 2025. – URL: <https://www.zr.ru/content/news/974745-uchenye-sozdali-dorozhnyj-oraku/> (дата обращения: 26.02.2026).
6. В Ростове-на-Дону создали дорожного «оракула» // Hi-Tech Mail: сайт. – 2025. – URL: <https://hi-tech.mail.ru/news/137604-v-rostove-na-donu-sozdali-dorozhnogo-orakula/> (дата обращения: 26.02.2026).
7. Прогнозирование транспортной загруженности с использованием методов машинного обучения // [SciNetwork.ru](https://scinetwork.ru): сайт. – 2025. – URL: <https://scinetwork.ru/disk?uid=74922> (дата обращения: 26.02.2026).