

УДК 004.6

Мешков Никита Сергеевич
студент кафедры «Автоматизированных
систем управления биотехнологическими процессами»
Российский биотехнологический университет (РОСБИОТЕХ)

НЕЙРОСЕТЕВЫЕ МОДЕЛИ ДЛЯ ПРОГНОЗИРОВАНИЯ ЭНЕРГОПОТРЕБЛЕНИЯ И НАГРУЗКИ ЭЛЕКТРОСЕТЕЙ. ЛИТЕРАТУРНЫЙ ОБЗОР И СРАВНЕНИЕ С ТРАДИЦИОННЫМИ МЕТОДАМИ ПРОГНОЗА

Аннотация. В статье сравниваются статистические и нейросетевые методы прогнозирования энергопотребления. Показано, что нейросети точнее и устойчивее классических моделей. Сравнение выполнено по метрикам MAE, RMSE и MAPE. Рассмотрены проблемы интерпретируемости, сложности и внедрения ИИ. Выделены перспективы Explainable AI, графовых сетей и обучения с подкреплением.

Ключевые слова: Нейросетевые модели, прогнозирование энергопотребления, нагрузка электросетей, ARIMA, LSTM, трансформеры, Smart Grid, искусственный интеллект, гибридные системы.

Введение

Современная энергетика находится на этапе активной цифровой трансформации, сопровождаемой внедрением интеллектуальных технологий, систем автоматического управления и аналитических инструментов. В этих условиях точное прогнозирование энергопотребления становится ключевой задачей для энергосбытовых компаний и операторов сетей, так как именно прогноз лежит в основе планирования генерации, оптимизации оборудования и оценки пиковых нагрузок. Ошибки приводят к финансовым потерям и снижению надёжности электроснабжения, что подтверждает актуальность проблемы.

Долгое время прогнозирование энергопотребления основывалось на классических статистических моделях – регрессионных зависимостях, методах скользящего среднего, экспоненциального сглаживания и авторегрессионных интегрированных моделях ARIMA и SARIMA [2]. Эти подходы позволяли учитывать сезонные тренды и временные зависимости, но оказались недостаточно гибкими при росте объёмов данных и усложнении факторов, влияющих на энергопотребление.

Развитие вычислительных мощностей и распространение машинного обучения привели к переходу от статистических методов к нейросетевым моделям, способным выявлять скрытые зависимости между множеством переменных и адаптироваться к изменениям среды [5]. Наибольшее применение нашли многослойные перцептроны (MLP), рекуррентные сети (RNN, LSTM, GRU) и свёрточные сети (CNN), каждая из которых демонстрирует преимущества при анализе временных рядов и многомерных данных.

Качество прогноза во многом определяется корректной подготовкой обучающих выборок. Данные об энергопотреблении нередко содержат шумы, выбросы и пропуски, вызванные погодными и социально-экономическими факторами. Нейросетевые подходы позволяют учитывать эти особенности за счёт автоматического выделения ключевых признаков и формирования гибридных моделей, сочетающих преимущества статистических и интеллектуальных методов.

Несмотря на высокую точность, применение нейросетей осложняется большой вычислительной нагрузкой и ограниченной интерпретируемостью результатов. По этой причине особый интерес представляет сравнение нейросетевых и традиционных методов прогнозирования, позволяющее определить границы их эффективности и практической применимости.



1.1 Особенности энергетических нагрузок и факторов, влияющих на потребление.

Энергетические нагрузки представляют собой совокупность процессов, отражающих характер потребления электроэнергии в разных секторах экономики и быту. На их величину влияют природно-климатические, экономические и поведенческие факторы. Точность прогноза определяется способностью модели учитывать эти взаимосвязи, что делает задачу моделирования одной из наиболее сложных в инженерной аналитике.

Энергопотребление формируется под воздействием закономерных и случайных факторов. К закономерным относятся суточные и сезонные колебания – пики в утренние и вечерние часы, рост потребления зимой из-за отопления и летом из-за кондиционирования. К случайным – изменения в экономике, тарифной политике и технологическом развитии. Влияние погодных условий особенно заметно: температура, влажность, скорость ветра и солнечная активность напрямую коррелируют с уровнем потребления энергии [3].

На энергопотребление воздействуют и социально-поведенческие изменения: переход на дистанционную работу, распространение бытовой техники с высокой мощностью и развитие распределённой генерации – солнечных панелей и систем накопления. Эти тенденции повышают вариативность нагрузки и требуют адаптивных, обучающихся моделей, способных подстраиваться под динамичные условия.

Традиционные статистические методы не всегда учитывают нелинейные взаимодействия. Их точность снижается при резких изменениях температуры или экономической активности. Даже усовершенствованные модели, такие как ARIMA и SARIMA, корректно работают лишь при стабильных временных зависимостях и неустойчивы к аномалиям.

Современные подходы используют интеграцию множества источников данных – исторических, погодных, календарных и социальных показателей. Такой подход требует высокой вычислительной мощности и гибких алгоритмов обработки информации. В этих условиях нейросетевые методы продемонстрировали наибольшую эффективность при работе с многомерными и нелинейными зависимостями.

Для построения точных моделей важно учитывать пространственную структуру энергосистемы. В городах нагрузка распределяется неравномерно: промышленные зоны активны днём, жилые – утром и вечером. В сельской местности энергопотребление подвержено сезонным колебаниям, связанным с сельхозциклом. Это требует построения локальных моделей, адаптированных к специфике регионов.

Случайные возмущения – аварии, отключения и непредсказуемые колебания спроса – учитываются с помощью механизмов сглаживания и регуляризации. В традиционных моделях они рассматриваются как выбросы, тогда как нейросетевые подходы способны использовать их для обучения устойчивости к шумам.

Прогнозы различаются по горизонту: краткосрочные (часы-сутки), среднесрочные (неделя-месяц) и долгосрочные (годы). Первые опираются на методы анализа временных рядов, вторые и третьи – на макроэкономические и демографические параметры. Гибридные модели, совмещающие статистическую фильтрацию и уточнение нейросетями, обеспечивают наилучшие результаты.

В целом энергетические нагрузки формируются под влиянием физических, экономических и социальных факторов. Их сложная природа исключает универсальные модели, одинаково эффективные во всех условиях. Поэтому развитие адаптивных систем прогнозирования, основанных на машинном обучении и нейросетевых технологиях, становится ключевым направлением современной энергетической аналитики.

1.2 Классические методы прогнозирования энергопотребления.

Традиционные методы прогнозирования энергопотребления появились задолго до машинного обучения и основаны на статистическом анализе временных рядов. Они описывают зависимости между потреблением электроэнергии и внешними факторами – температурой, временем суток, сезоном и экономической активностью [1]. Несмотря на распространение интеллектуальных технологий, классические модели востребованы благодаря простоте, интерпретируемости и низким вычислительным затратам.



К числу базовых инструментов относится регрессионный анализ. Простая линейная регрессия оценивает влияние одного фактора, множественная – нескольких переменных одновременно. Такие модели позволяют статистически оценивать значимость факторов, однако плохо отражают нелинейные зависимости.

Методы сглаживания временных рядов – скользящее и экспоненциальное сглаживание – используются для краткосрочных прогнозов. Они реагируют на изменения тенденций, но теряют точность при наличии шумов и скачков нагрузки.

Особое место занимают авторегрессионные модели ARIMA и SARIMA, учитывающие сезонность и временные зависимости. Эти модели эффективны при устойчивых данных, но плохо адаптируются к нелинейным процессам и аномалиям. Для учёта сезонных эффектов применяются регрессионно-сезонные модели, однако их настройка требует ручной корректировки параметров.

Спектральный анализ используется для выявления скрытых циклов и ритмов потребления. В сочетании с авторегрессией он повышает точность прогноза, но требует больших вычислительных ресурсов и фильтрации данных.

Для повышения гибкости применяются регрессионные деревья и методы кластеризации, разделяющие данные на группы по схожим характеристикам. Это повышает точность, но снижает прозрачность модели.

Детерминированность остаётся главным ограничением классических подходов – модели не обучаются автоматически и требуют ручного обновления параметров. Это снижает их применимость в условиях быстро меняющегося энергетического сектора, где появляются новые типы нагрузок и интеллектуальные сети.

Метод наименьших квадратов (МНК) используется для минимизации ошибок прогноза и построения оптимальных аппроксимаций, но чувствителен к выбросам и предполагает нормальность распределения ошибок. Метод аналогов ищет сходные периоды в исторических данных, однако его эффективность снижается при изменении внешних условий.

Экспертные системы и сценарный анализ применяются при долгосрочном прогнозировании, когда необходимо учитывать технологические и социально-экономические тенденции. Недостаток – высокая субъективность результатов.

В целом классические методы эффективны при стабильных условиях, но ограничены в учёте динамичных и нелинейных процессов. Сегодня они используются как базовые инструменты для обучения и сравнения нейросетевых систем, образуя основу гибридных моделей, сочетающих прозрачность статистики и точность интеллектуальных алгоритмов.

1.3 Эффективность и проблемы традиционных моделей прогнозирования энергопотребления.

Эффективность традиционных методов прогнозирования энергопотребления обусловлена их математической простотой и интерпретируемостью. Эти модели десятилетиями применяются в энергетике и остаются востребованными при краткосрочном и среднесрочном прогнозировании в устойчивых условиях. Их ключевое достоинство – прозрачность: каждый коэффициент имеет статистическое значение, позволяющее оценить вклад отдельных факторов, например температуры или дня недели, в изменение нагрузки [2].

Однако гибкость таких моделей ограничена. Классические методы основаны на предположениях о линейности и стационарности данных, что редко выполняется в реальных энергосистемах. Влияние возобновляемых источников, изменчивость климата и поведение потребителей приводят к снижению точности прогнозов.

Существенной проблемой является отсутствие механизма автоматической адаптации. Параметры моделей фиксируются после обучения и требуют перекалибровки при изменении закономерностей, например при росте числа электромобилей. Это делает обновление моделей трудоёмким процессом.

Традиционные методы также чувствительны к шумам и выбросам, возникающим при авариях, пиковых нагрузках и погодных аномалиях. Фильтрация данных лишь частично решает проблему, поскольку искажает реальные зависимости. При этом средняя ошибка краткосрочного прогноза обычно составляет 3-8 %, а при увеличении горизонта достигает 15-25 %.



Ограничением остаётся и неспособность описывать нелинейные зависимости. Например, при низких температурах потребление растёт экспоненциально, а в умеренных условиях влияние почти отсутствует. Попытки учесть такие эффекты через полиномиальные регрессии часто приводят к переобучению. Проблему усугубляет мультиколлинеарность – сильная корреляция между переменными, делающая параметры нестабильными.

Главное преимущество классических подходов – высокая вычислительная эффективность. Они требуют минимальных ресурсов и применяются для оперативных расчётов в распределённых системах. В современных условиях такие модели часто используются в составе гибридных схем: регрессионная часть выполняет предварительный анализ, а нейросетевой блок уточняет прогноз.

Классические методы остаются ценным инструментом энергетической аналитики, обеспечивая прозрачность и устойчивость при ограниченных данных. Однако их линейная природа и низкая адаптивность ограничивают возможности при работе с динамичными системами. Переход к нейросетевым моделям, способным обучаться и учитывать нелинейные зависимости, стал закономерным этапом развития прогнозных технологий в энергетике.

2.1 Основные архитектуры нейросетей, применяемые в прогнозировании энергопотребления.

Переход от статистических моделей к нейросетевым методам стал ключевым этапом развития аналитики в энергетике. Искусственные нейронные сети (ИНС) способны распознавать нелинейные зависимости, учитывать широкий спектр факторов и адаптироваться к изменениям среды. В отличие от фиксированных формул классических моделей, нейросети обучаются на данных, повышая точность прогнозов за счёт оптимизации внутренних весов.

Первые в энергетике применялись многослойные перцептроны (MLP), использующие функции активации ReLU, sigmoid или tanh. Они успешно аппроксимируют сложные зависимости и обеспечивают хорошие результаты при анализе агрегированных временных рядов, но ограничены в учёте последовательности событий. Для анализа временных зависимостей используются рекуррентные сети (RNN), однако они подвержены эффекту исчезающего градиента. Модификации LSTM и GRU решают эту проблему, позволяя сохранять информацию на длительных промежутках и эффективно учитывать сезонные и поведенческие паттерны [3].

Свёрточные сети (CNN), изначально предназначенные для анализа изображений, применяются в прогнозировании энергопотребления для автоматического выделения признаков и распознавания повторяющихся шаблонов нагрузки. В гибридных моделях CNN комбинируются с LSTM, объединяя пространственный и временной анализ.

Глубокие нейронные сети (DNN) включают множество скрытых слоёв и подходят для обработки больших массивов данных, например телеметрии от тысяч датчиков. Их главным ограничением остаются вычислительные затраты и риск переобучения при малом объёме данных.

Одним из наиболее перспективных направлений стали трансформеры и архитектуры с механизмом внимания (attention), способные учитывать долгосрочные зависимости без рекуррентных связей. Они повышают скорость обучения и точность прогнозов, особенно при многомерных временных рядах.

Для пространственного моделирования применяются графовые нейронные сети (GNN), которые учитывают взаимосвязи между узлами энергосистем – подстанциями, генераторами и потребителями. Это делает возможным моделирование потоков энергии в сетях Smart Grid.

Высокие результаты дают также ансамблевые и гибридные системы, объединяющие разные архитектуры (например, CNN и LSTM) или совмещающие нейросетевые и статистические подходы. Такой синтез позволяет повысить устойчивость и уменьшить ошибки прогнозирования.



По метрикам MAE, RMSE и MAPE нейросети демонстрируют точность в 1,5–2 %, что в несколько раз лучше результатов классических моделей. Однако их обучение требует подбора гиперпараметров – количества слоёв, нейронов, скорости обучения и функций активации. Для предотвращения переобучения применяются методы кросс-валидации, дропаута и нормализации.

Современные нейросетевые архитектуры обеспечивают высокую точность и адаптивность прогнозов, что делает их основой интеллектуальных систем энергоменеджмента. Они позволяют не только предсказывать энергопотребление, но и оптимизировать распределение ресурсов в режиме реального времени.

2.2 Преимущества нейросетевых подходов перед классическими методами прогнозирования энергопотребления

Переход от статистических моделей к нейросетевым технологиям стал закономерным этапом цифровой трансформации энергетики. Классические методы, несмотря на простоту, ограничены линейными зависимостями и не учитывают сложную динамику внешних факторов. Нейросетевые подходы обеспечивают адаптивное обучение, устойчивость к шумам и работу с большими объёмами данных, что делает их наиболее эффективными для прогнозирования энергопотребления.

Главное преимущество нейросетей – способность моделировать нелинейные зависимости без заранее заданных уравнений. Это важно в энергетике, где на потребление влияют не только температура и время суток, но и тарифная политика, уровень экономической активности и поведение пользователей. Нейросеть выявляет скрытые закономерности между множеством параметров, обеспечивая более точные прогнозы.

Высокая адаптивность позволяет моделям самостоятельно обновлять параметры при изменении данных. Нейросеть дообучается без ручной перекалибровки, что особенно ценно для систем, работающих в режиме реального времени.

Современные энергетические платформы генерируют терабайты телеметрических и климатических данных. Глубокие нейронные сети (DNN) способны эффективно выделять значимые признаки и устранять шум, обеспечивая точные прогнозы даже при нестабильных входных данных.

Нейросети также устойчивы к выбросам: архитектуры LSTM и GRU учитывают долгосрочные зависимости и фильтруют случайные колебания, что повышает надёжность прогнозов. Важным преимуществом является автоматическое извлечение признаков – сеть сама определяет значимые факторы, исключая человеческий субъективизм. Особенно эффективно это реализовано в свёрточных сетях (CNN), распознающих суточные и недельные циклы потребления [6].

Нейросетевые модели позволяют прогнозировать сразу несколько показателей – нагрузку по регионам, сегментам потребителей или типам генерации. Это делает их незаменимыми для диспетчеризации и планирования распределённых систем.

Точность нейросетей подтверждается практическими результатами: ошибки прогнозов LSTM и гибридных CNN-LSTM составляют 1,5–2 %, что в два–три раза ниже, чем у классических методов. Даже снижение ошибки на 1–2 % даёт значительный экономический эффект за счёт оптимизации генерации.

Гибридные архитектуры, объединяющие CNN, RNN и механизмы внимания (attention), обеспечивают точное учёт пространственно-временных факторов и быструю реакцию на изменения контекста. Они масштабируемы и могут использоваться как на уровне локальных сетей, так и в национальных энергосистемах.

Современные решения интегрируются в SCADA-системы, облачные платформы и цифровые двойники, формируя основу интеллектуальных энергетических комплексов Smart Grid. Нейросети обеспечивают повышение точности прогнозов, сокращение времени их обновления и устойчивость к неполным данным, что делает возможным переход к саморегулируемым системам управления энергопотреблением.



2.3 Сравнительный анализ точности прогнозов нейросетевых и традиционных методов.

Сравнение нейросетевых и классических методов прогнозирования энергопотребления позволяет оценить влияние искусственного интеллекта на качество прогнозов и устойчивость энергосистем. Точность предсказания нагрузки является ключевым показателем эффективности, определяющим баланс между генерацией и потреблением, а также надёжность электроснабжения.

Оценка моделей выполняется на основе исторических временных рядов, содержащих данные о почасовом или суточном потреблении, температуре, влажности и календарных параметрах. Для измерения точности используются метрики MAE, RMSE и MAPE – чем ниже их значения, тем надёжнее модель.

При анализе типовых отраслевых данных (приведенных в таблице 1), нейросетевые архитектуры демонстрируют заметное преимущество над классическими подходами. Это подтверждает высокую адаптивность и способность искусственных сетей учитывать сложные нелинейные зависимости между факторами, влияющими на энергопотребление.

Таблица 1

Сравнение точности прогнозов различных методов прогнозирования энергопотребления.

Тип модели	Пример архитектуры / алгоритма	MAE, %	RMSE, %	MAPE, %	Характеристика
Линейная регрессия	Множественная регрессия с температурными и календарными переменными	4.5	6.2	5.1	Простая и интерпретируемая модель, чувствительная к выбросам
ARIMA	ARIMA (2,1,2), сезонность 24 ч	3.9	5.6	4.3	Устойчива при стабильных временных рядах, не учитывает нелинейности
SARIMA	SARIMA (1,1,1) (1,0,1) ₂₄	3.6	5.2	3.9	Лучше справляется с сезонными компонентами, но не адаптивна
Многослойный перцептрон (MLP)	3 скрытых слоя, ReLU, Adam	2.3	3.5	2.8	Хорошая точность при большом объеме данных, требуется настройка гиперпараметров
Рекуррентная нейронная сеть (RNN)	tanh, SGD	2.0	3.3	2.5	Учитывает временные зависимости, но чувствительна к длине ряда
LSTM	2 слоя LSTM + Dropout	1.7	2.8	2.1	Оптимальна для временных рядов, устойчива к шумам
CNN-LSTM (гибридная модель)	Свёрточные и рекуррентные блоки	1.5	2.4	1.8	Высокая точность, эффективна при больших массивах данных
Трансформер	Encoder-Decoder с attention	1.3	2.2	1.6	Лучшая адаптация к сложным паттернам, высокая вычислительная нагрузка



Анализ показывает, что нейросетевые модели значительно превосходят классические по всем основным метрикам прогнозирования энергопотребления. Среднее снижение ошибки достигает 30–60 % в зависимости от архитектуры и сложности задачи. Особенно высокие результаты обеспечивают рекуррентные сети (LSTM, GRU) и гибридные модели CNN-LSTM, успешно учитывающие сезонные и внутрисуточные колебания.

Главное преимущество нейросетей – способность выявлять нелинейные зависимости и учитывать отложенные эффекты. Так, LSTM может распознавать задержанное влияние температуры: рост дневной температуры приводит к увеличению потребления вечером, что недоступно классическим моделям ARIMA.

Гибридные архитектуры, совмещающие свёрточные и рекуррентные слои, обеспечивают оптимальный баланс между локальным и долгосрочным анализом данных. Свёрточные блоки фиксируют повторяющиеся шаблоны потребления, а рекуррентные – долгосрочные тенденции, что особенно полезно для городских энергосистем с регулярными пиковыми циклами.

Модели на основе трансформеров демонстрируют ещё более высокую точность за счёт механизма внимания, который позволяет анализировать взаимосвязи между всеми элементами временного ряда. Это делает их эффективными при прогнозах на горизонтах до недели.

Недостатком нейросетей остаются высокие вычислительные требования и риск переобучения. Для устойчивости результатов применяются методы регуляризации, dropout, кросс-валидации и ранней остановки обучения. Несмотря на это, нейросетевые решения обеспечивают более стабильные прогнозы, что позволяет оптимизировать графики генерации, снизить потери и повысить экономическую эффективность сетей.

Точные прогнозы способствуют выравниванию баланса между спросом и предложением и повышают надёжность энергосистем. Минимизация отклонений между плановым и фактическим потреблением предотвращает перетоки мощности и стабилизирует сеть [7].

Современная практика показывает интеграцию нейросетевых моделей в автоматизированные комплексы управления, формирующие не только прогноз, но и рекомендации по оптимальным режимам генерации и распределения нагрузки. Это отражает переход от пассивного анализа к активному интеллектуальному управлению.

По совокупности критериев нейросетевые подходы превосходят традиционные по точности, устойчивости, способности к самообучению и интеграции в системы реального времени. Применение таких технологий обеспечивает рост эффективности и надёжности энергетических систем, формируя основу интеллектуального энергетического менеджмента и устойчивого развития отрасли.

3.1 Тенденции развития интеллектуальных систем управления энергопотреблением.

Современная энергетика активно переходит к интеллектуальным системам управления, способным адаптироваться к динамичным условиям и повышенным требованиям надёжности. Основу этой трансформации составляют нейросетевые технологии, обеспечивающие прогнозирование и оптимизацию энергопотребления [5].

Традиционные системы управления действовали по принципу реактивного анализа – реагировали на отклонения после их возникновения. Современные решения реализуют предиктивное управление: нейросети прогнозируют изменения нагрузки и корректируют режимы работы оборудования заранее, предотвращая перегрузки.

Интеграция с концепцией Smart Grid обеспечивает двустороннюю связь между потребителями и поставщиками. Нейросети анализируют данные интеллектуальных счётчиков и формируют рекомендации по сглаживанию пиков нагрузки, повышая эффективность инфраструктуры.

Использование Интернета вещей (IoT) расширяет возможности анализа: миллионы сенсоров передают телеметрию, на основе которой нейросети прогнозируют потребление и



автоматически регулируют работу оборудования. Аналогичный принцип применяется в цифровых двойниках энергетических объектов – виртуальных моделях, которые прогнозируют износ оборудования и предотвращают аварии.

В условиях роста доли возобновляемых источников энергии нейросети позволяют стабилизировать баланс генерации и потребления, предсказывая выработку в зависимости от погодных факторов. Они также применяются для повышения энергоэффективности зданий и предприятий, выявления нерациональных расходов и автоматического регулирования систем отопления и освещения.

Системы управления спросом (Demand Response) используют нейросетевые прогнозы для определения пиков потребления и заблаговременного перераспределения нагрузки. В сочетании с облачными и периферийными вычислениями такие решения обеспечивают гибкость и устойчивость энергосетей.

Нейросетевые модели находят применение и в энергетическом трейдинге: прогнозирование цен на электроэнергию позволяет оптимизировать закупки и повысить конкурентоспособность компаний.

Интеграция нейросетей с системами хранения энергии создаёт возможность балансировки потребления и генерации в реальном времени. Это способствует развитию «живых» энергосетей, способных к самообучению и адаптации без участия человека.

В целом, нейросетевые технологии формируют новую парадигму предиктивного управления энергосистемами, обеспечивая высокую точность прогнозов, энергоэффективность и устойчивое развитие отрасли.

3.2 Проблемы внедрения и интерпретируемости нейросетевых моделей в энергетике.

Несмотря на успехи нейросетевых технологий, их внедрение в энергетику сталкивается с рядом трудностей. Главные проблемы связаны с вычислительной сложностью, низкой интерпретируемостью, зависимостью от качества данных и отсутствием единых стандартов [9].

Обучение нейросетей требует больших массивов чистых и согласованных данных, однако в энергетике часто встречаются пропуски, шумы и различия в форматах. Предварительная обработка – фильтрация, нормализация и коррекция – требует значительных ресурсов.

Интерпретируемость моделей остаётся серьёзным барьером. В отличие от классических подходов, нейросети действуют как «чёрный ящик», что вызывает недоверие при принятии управленческих решений. Для повышения прозрачности развиваются методы Explainable AI, но они пока не стандартизированы.

Сложность обучения и регулярное переобучение требуют мощных вычислительных систем, что недоступно для многих региональных предприятий. К этому добавляются проблемы несовместимости старых SCADA-систем с новыми цифровыми решениями и дефицит специалистов по машинному обучению.

Особую угрозу представляет кибербезопасность: вмешательство в каналы передачи данных может исказить входные сигналы и вызвать ошибочные прогнозы. Поэтому защита данных и верификация алгоритмов становятся ключевыми задачами.

Переобучение также снижает надёжность – при чрезмерной сложности сеть запоминает обучающие данные, теряя способность к обобщению. Решения включают регуляризацию и увеличение объёма обучающей выборки.

Дальнейшее развитие отрасли связано с внедрением Explainable AI, стандартизацией и интеграцией нейросетей в гибридные модели, где прозрачность обеспечивается статистическими методами, а точность – искусственным интеллектом. Это создаёт основу для устойчивого внедрения нейросетевых технологий в управление энергопотреблением.

3.3 Возможные направления совершенствования моделей прогнозирования энергопотребления.

Совершенствование моделей прогнозирования энергопотребления остаётся приоритетным направлением развития энергетической аналитики. Несмотря на достигнутую



точность нейросетей, потенциал их улучшения значителен. Будущее связано с созданием гибридных архитектур, интеграцией разнородных данных и повышением прозрачности моделей [7].

Главная тенденция – внедрение трансформеров с механизмом внимания (attention), способных учитывать долгосрочные зависимости между параметрами и обеспечивать более высокую точность при меньших затратах вычислений. Их адаптация к энергетическим данным позволит повысить эффективность прогнозов.

Развитие гибридных систем, объединяющих статистические и нейросетевые методы, позволяет совместить устойчивость классических алгоритмов с адаптивностью ИИ. Такие подходы снижают чувствительность к шумам и обеспечивают стабильность моделей.

Графовые нейронные сети (GNN) находят применение при моделировании пространственно-временных связей между элементами энергосистемы. Они позволяют предсказывать нагрузку на отдельных участках сети и оптимизировать распределение мощности.

Методы обучения с подкреплением (RL) превращают прогнозные модели в активных участников управления, обеспечивая оптимизацию режимов работы оборудования и сокращение пиковых нагрузок.

Особое значение приобретают интерпретируемость и прозрачность. Технологии Explainable AI (LIME, SHAP) позволяют визуализировать влияние факторов на прогноз и повышают доверие к моделям.

Интеграция мультимедийных данных – от погодных и поведенческих до экономических и промышленных показателей – делает прогнозы комплексными и контекстно чувствительными.

Параллельно развиваются энергоэффективные «лёгкие» нейросети (Lightweight NN), использующие квантование и обрезку весов для сокращения вычислительных затрат. Это особенно важно при применении ИИ в распределённых системах и устройствах IoT.

Будущее связано с самообучающимися системами, способными автоматически адаптироваться к изменению структуры данных и предотвращать деградацию точности. Их интеграция с системами хранения энергии создаёт основу для автономных энергосетей нового поколения.

В долгосрочной перспективе прогнозные модели станут частью когнитивного управления, при котором системы не только анализируют, но и самостоятельно принимают решения, обеспечивая устойчивость и гибкость энергетической инфраструктуры.

Заключение

Современная энергетика демонстрирует растущую роль нейросетевых технологий как ключевого инструмента прогнозирования энергопотребления и оптимизации электросетей. Переход от традиционных методов анализа к интеллектуальным системам повысил точность прогнозов, адаптивность к динамичным условиям и реализовал принципы предиктивного управления энергоресурсами.

В первой части статьи рассмотрены факторы формирования энергетических нагрузок и ограничения традиционных статистических методов (регрессии, ARIMA), эффективных лишь при стабильных временных рядах. Показано, что многомерная структура энергопотребления, зависящая от климатических, экономических и поведенческих факторов, требует более гибких моделей.

Во второй части анализируются нейросетевые подходы – MLP, LSTM, GRU, CNN и их гибриды. Они демонстрируют значительно более высокую точность и устойчивость прогнозов за счёт способности обучаться на больших массивах данных и выявлять скрытые зависимости. Среднее снижение ошибок составляет 30–60 %, что существенно повышает эффективность управления энергосистемами.

Отмечена роль интеграции нейросетей в интеллектуальные энергетические платформы. В рамках Smart Grid прогнозирование становится основой адаптивного управления, объединяя ИИ, Интернет вещей, цифровые двойники и системы хранения энергии. Это позволяет балансировать нагрузку, повышать надёжность и снижать потери.



Среди проблем выделены высокая вычислительная сложность, потребность в больших обучающих выборках, ограниченная интерпретируемость и риски кибербезопасности. Пути решения – развитие Explainable AI, гибридных архитектур, энергоэффективных вычислений и стандартов доверенного ИИ.

Основные выводы:

нейросетевые методы обеспечивают более высокую точность прогнозов, чем традиционные модели;

их применение повышает устойчивость и эффективность энергосистем;

гибридные и трансформерные архитектуры формируют основу интеллектуальных энергетических экосистем;

ключевые задачи – повышение интерпретируемости и стандартизация внедрения ИИ.

Таким образом, нейросетевые технологии становятся фундаментом новой модели энергетического управления, где данные и прогнозы служат инструментом стратегического развития. Искусственный интеллект обеспечивает переход к самообучающимся и саморегулируемым системам, способным оптимизировать распределение ресурсов и поддерживать устойчивое развитие электроэнергетики

Список литературы:

1. Бэнн Д. В., Фармер Е. Д. Сравнительные модели прогнозирования электрической нагрузки: пер. с англ. – М.: Энергоатомиздат, 1987. – 200 с.
2. Гордеев В. И., Васильев И. Е., Щуцкий В. И. Управление электропотреблением и его прогнозирование. – Ростов н/Д: Изд-во РГУ, 1991. – 104 с.
3. Гурский С. К. Адаптивное прогнозирование временных рядов в электроэнергетике. – Минск: Наука и техника, 1983. – 271 с.
4. Закарюкин В. П., Крюков А. В., Раевский Н. В., Яковлев Д. А. Моделирование и прогнозирование процессов электропотребления на железнодорожном транспорте: монография. – Иркутск, 2007. – 114 с.
5. Манусов В. З., Родыгина С. В. Нейронные сети: прогнозирование электрической нагрузки и потерь мощности в электрических сетях. От романтики к прагматике: монография. – Новосибирск: Изд-во НГТУ, 2018. – 303 с.
6. Манусов В. З., Хасанзода Н., Матренин П. В. Применение методов искусственного интеллекта в задачах управления режимами электрических сетей Smart Grid: монография. – Новосибирск: Изд-во НГТУ, 2019. – 240 с.
7. Полуянович Н. К., Дубяго М. Н., Бурьков Д. В. Нейросетевой метод прогнозирования электропотребления и его инструментальная реализация: монография. – Ростов н/Д; Таганрог: Изд-во Южного федерального ун-та, 2023. – 183 с.
8. Прогнозирование и управление электропотреблением в электроэнергетических системах / под ред. В. Д. Шлимовича. – М.: ВИНТИ, 1988. – 236 с.
9. Филиппова Т. А., Русина А. Г., Дронова Ю. В. Модели и методы прогнозирования электроэнергии и мощности при управлении режимами электроэнергетических систем: монография. – Новосибирск: Изд-во НГТУ, 2009. – 368 с.
10. Шумилова Г. П., Готман Н. Э., Старцева Т. Б. Прогнозирование электрических нагрузок при оперативном управлении электроэнергетическими системами на основе нейросетевых структур. – Екатеринбург: УрО РАН, 2008. – 89 с

