

УДК 338.45 DOI: 10.14451/1.243.322

Прогнозирование спроса на электроэнергию в энергетических системах со стохастическим паттерном потребления

© 2025 Тимохин Роман Владимирович

Аспирант, руководитель проектов в компании Hyper. Национальный исследовательский университет Московский Энергетический Институт, Москва, Россия.

E-mail: TimokhinRV@mpei.ru

Ключевые слова: прогнозирование потребления энергии, паттерны потребления и спроса, тарифная политика, энергетические системы, оптимизация издержек.

Электроэнергетический сектор в последние годы претерпевает значительные изменения, связанные с появлением новых типов потребителей, что значительно меняет структуру нагрузки. Увеличение потребности в электроэнергии от крупных центров обработки данных (ЦОД), обеспечивающих работу искусственного интеллекта, а также развитие криптовалют и блокчейн-технологий, ставящих высокие требования к вычислительным мощностям, создают дополнительную нагрузку на энергосистемы. Эти потребители, как правило, характеризуются стационарными графиками потребления с незначительными колебаниями в штатных условиях функционирования. Однако наряду с этим активно развиваются новые потребители с более стохастическими паттернами потребления, такими как электромобили, потребление которых подвержено более выраженным краткосрочным колебаниям. В условиях таких изменений прогнозирование потребности в энергии становится ключевым для оптимизации издержек, разработки эффективной тарифной политики и управления энергетическими ресурсами. Статья посвящена разработке моделей прогнозирования спроса на электроэнергию с учетом стохастичных паттернов потребления, что позволяет более точно оценивать динамику нагрузки и выстраивать экономически эффективные стратегии управления потребителями в условиях изменяющегося спроса и высокой неопределенности.

Введение

Электроэнергетическая отрасль сталкивается с кардинальными изменениями в связи с внедрением новых типов потребителей энергии. Одним из таких потребителей, оказывающих значительное влияние на энергосистемы, являются электромобили. По данным ГИБДД на конец 2024 года, количество чистых электромобилей в России составило 61 тысячу единиц, что представ-

ляет собой более чем 75% рост по сравнению с предыдущим годом [1].

На данный момент электромобили составляют лишь около 0,12% от общего числа легковых автомобилей в России. Однако их влияние на энергосистему значительно возрастает, поскольку зарядка электромобилей вызывает пиковые нагрузки в сети, особенно в вечернее время и в выходные дни. Такие изменения требуют разработ-

ки новых подходов к прогнозированию спроса на электроэнергию, которые будут учитывать стохастические паттерны потребления, характерные для электромобилей.

Особенности потребления энергии такими потребителями заключаются в высокой вариативности спроса в зависимости от времени суток, дня недели, погоды и прочих факторов, специфичных для данных потребителей, а также стохастического характера. При этом уровень потребления электроэнергии электромобилями на определенных участках сети может значительно отличаться от традиционных потребителей, что требует применения более точных методов прогнозирования. Существующие статистические модели, такие как **SARIMA**, которые используют данные о сезонных колебаниях и автокорреляциях, не могут адекватно учитывать влияние этих новых факторов. Для точного прогнозирования необходимы более сложные гибридные модели, способные интегрировать данные о стоимости электроэнергии, плотности трафика, температуре и инфраструктуре зарядных станций.

Прогнозирование спроса на электроэнергию с учетом таких стохастических потребителей, как электромобили, становится ключевым элементом для оптимизации работы энергосистем и разработки эффективной тарифной политики. Точные прогнозы позволяют предсказывать пиковые нагрузки и корректировать управление энергопотреблением, что способствует снижению издержек на производство и распределение электроэнергии. Таким образом, создание моделей, способных интегрировать динамические факторы, является важным шагом в направлении устойчивого развития энергетических систем.

Методы

В ходе исследования использовались методы анализа и синтеза информации для изучения изменений в структуре энергопотребления, вызванных развитием стохастических потребителей. Прогнозирование применялось для оценки динамики спроса на электроэнергию с учетом

временных и стохастических факторов, включая сезонные колебания, плотность трафика, температурные условия и инфраструктурные ограничения. Методы теоретического моделирования были использованы для разработки концептуальной модели прогнозирования спроса, интегрирующей статистические методы, машинное обучение и нейронные сети для повышения точности предсказаний и оптимизации энергопотребления.

Актуальность

В последние годы в энергосистеме происходят значительные изменения в части характера нагрузки и типов потребителей в связи с развитием новых отраслей. Например, внедрение электрического транспортного средства значительно влияет на спрос на электроэнергию и распределение нагрузки в энергосистемах. Согласно утвержденной Правительством Российской Федерации в 2021 году Концепции по развитию производства и использования электрического автомобильного транспорта до 2030 года, предполагаются три основных сценария, которые описывают возможное развитие электромобильности в стране: инерционный, сбалансированный и ускоренного развития [2].

Каждый из этих сценариев имеет свои особенности, которые влияют на темпы роста числа электромобилей и, соответственно, на потребление электроэнергии. При этом важно учитывать, что хотя предполагаемое потребление электроэнергии со стороны электромобилей в сумме будет составлять всего около 0,3% от общего потребления в 2030 году, нагрузка на энергосистему распределяется неравномерно в течение суток, что создает дополнительные вызовы для эффективного управления энергоснабжением. Для наглядности составлен график доли потребления электроэнергии для различных электромобилей (рис. 1).

Как видно из приведенного рисунка нагрузка в пиковые часы, может достигнуть до 2,55% при достижении 10% доли проникновения электромобилей, что может и не много в относительном выражении, но в абсолютном — это




Рис. 1. Доля потребления электроэнергии различными автомобилями.

3,9 ГВт мощности потребления. Для сравнения, прогнозируемая установленная мощность всех электростанций энергосистемы Нижегородской области в 2030 г составит всего 2,8 ГВт [3].

Прогнозирование нагрузки стохастических потребителей, таких как электромобили, становится критически важным для разработки эффективных тарифных политик, оптимизации потребления и распределения энергии, а также для разработки и улучшения механизмов управления пиковыми нагрузками [4]. Таким образом, актуальность работы заключается в необходимости разработки моделей, которые могут точно прогнозировать потребность в электроэнергии и учитывать стохастические изменения, связанные с внедрением электромобилей. Эти модели должны обеспечивать высокую точность предсказаний, что позволит разработать стратегии для обеспечения устойчивости энергосистемы в условиях изменяющегося спроса.

Методы прогнозирования спроса на электроэнергию и их применение для прогноза потребления

Прогнозирование спроса на электроэнергию — это не просто задача для специалистов по энергетике, но и ключевая проблема для эффективного функционирования энергосистем. В последние годы с учетом развития новых типов потребителей, таких как электромобили, задача

прогнозирования становится еще более многогранной. Электромобили представляют собой потребителей с уникальными стохастическими паттернами потребления, что требует использования различных методов для точного прогноза. Существует несколько групп методов прогнозирования: статистические, методы машинного обучения и нейронные сети [5–7]. Рассмотрим каждую группу более детально, чтобы понять их применимость для прогноза потребления электромобилей.

Статистические методы являются основой традиционного прогнозирования спроса на электроэнергию. Одним из самых популярных инструментов является ARIMA (AutoRegressive Integrated Moving Average). Он используется для анализа временных рядов. Этот метод хорошо работает с данными, которые имеют явные тренды и сезонные компоненты. Применение SARIMA (Seasonal ARIMA) позволяет дополнительно учитывать сезонные колебания в потреблении, что особенно важно при прогнозировании долгосрочных изменений. Другим важным методом является Exponential Smoothing (ETS), который позволяет учитывать как тренды, так и сезонные колебания в данных с небольшими изменениями во времени. Эти методы применяются в энергетике для прогнозирования пиковых нагрузок в условиях стабильного потребления, но могут быть ограничены в работе с нестабильными

и стохастическими паттернами, характерными для электромобилей.

Методы машинного обучения представляют собой следующую группу инструментов, которые способны работать с более сложными и многомерными данными. Здесь наиболее часто используются Random Forest (RF), XGBoost и Support Vector Machines (SVM). Random Forest и XGBoost – это ансамблевые методы, которые способны обрабатывать огромное количество данных и учитывать множество внешних факторов, таких как экономические изменения, погодные условия, количество зарядных станций и т.д. Погодные условия в значительной степени влияют на энергопотребление, что подтверждено исследованиями [9]. XGBoost, в частности, отличается высокой точностью и эффективностью в задачах, где данные имеют сложную структуру. SVM применяются для классификации и регрессии, хорошо работают с малыми объемами данных и позволяют моделировать сложные зависимости. Однако данные методы требуют значительных вычислительных ресурсов и тщательной настройки гиперпараметров. В контексте электромобилей машинное обучение помогает учитывать изменения в потреблении, связанные с различными экзогенными факторами.

Нейронные сети, такие как LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Units), относятся к глубинному обучению и используются для анализа временных рядов, где важны долгосрочные зависимости. LSTM эффективен для прогнозирования потребления электроэнергии, где данные подвержены долгосрочным трендам и колебаниям, а также влияют экзогенные факторы, такие как скорость роста числа электромобилей или изменения в тарифах на электроэнергию. GRU, в свою очередь, является

более легковесной моделью, обеспечивающей хорошее качество прогнозов при меньших вычислительных затратах. Эти методы имеют высокую точность, но их обучение требует больших объемов данных, что может быть проблемой при ограниченных данных о зарядке электромобилей.

Эти методы применяются для прогнозирования потребления со стороны электромобилей, которые имеют уникальные стохастические паттерны потребления. Например, электромобили активно заряжаются в вечерние часы и ночное время, что влияет на распределение нагрузки в энергосистеме. Для учета таких изменений важно использовать гибридные модели, которые объединяют статистические методы для захвата сезонных компонентов и машинное обучение для учета экзогенных факторов и краткосрочных колебаний. Таким образом, методы машинного обучения и нейронные сети, применяемые для прогнозирования спроса на электроэнергию со стороны электромобилей, являются неотъемлемой частью развития современных энергосистем.

Для классификации методов прогнозирования можно привести следующую таблицу, которая детально описывает каждый метод, его преимущества, недостатки и суть, а также математическое описание.

Таким образом, выбор метода прогнозирования зависит от специфики задачи, доступных данных и требуемой точности прогноза. В случае с электромобилями, где потребление энергии нестабильно и зависит от множества факторов, комбинированные методы, такие как SARIMA + LSTM или XGBoost + LSTM, могут быть наиболее эффективными для точного прогноза и адекватного управления нагрузкой на энергосистему.

Таблица 1. Методы прогнозирования.

Тип метода	Название	Преимущества	Недостатки	Суть метода	Мат описание
Статистические методы	ARIMA	Простота, интерпретируемость, хорош для временных рядов с трендами	Не учитывает нелинейности и сложные зависимости	Моделирует зависимость временных рядов, учитывая авторегрессию и скользящие средние	$X_t = \mu + \sum_{i=1}^p \phi_i X_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t$
	SARIMA	Учитывает сезонность, хорошо работает с трендами и сезонными колебаниями	Не подходит для сложных и стохастических паттернов	Расширение ARIMA, которое включает сезонность	$\left(1 - \sum_{i=1}^p \phi_i B^i\right) (1 - B^S)^p X_t = \mu + \theta_0 + \sum_{i=1}^q \theta_j B^j \epsilon_{t-j}$
Машинное обучение	Random Forest	Устойчив к переобучению, хорошо работает с большими данными	Трудно интерпретировать, требует значительных вычислительных ресурсов	Ансамблевая модель, использующая множество деревьев решений	$\hat{y} = \frac{1}{N} \sum_{i=1}^N T_i(X)$
Машинное обучение	XGBoost	Высокая точность, способность работать с множеством признаков	Требует настройки гиперпараметров, вычислительно затратен	Градиентный бустинг деревьев решений	$\hat{y} = \sum_{i=1}^M \eta_i h_i(X)$
Машинное обучение	Support Vector Machines (SVM)	Хорошо работает с малыми объемами данных, эффективен при работе с высокоразмерными данными	Чувствителен к выбору гиперпараметров	Использует гиперплоскости для классификации и регрессии	$f(x) = w^T x + b$
Нейронные сети	LSTM	Захватывает долгосрочные зависимости, эффективен для временных рядов	Требует больших объемов данных и сложен в интерпретации	Рекуррентная нейронная сеть для обработки временных зависимостей	$h_t = \sigma(W_h \cdot x_t + b_h)$

Продолжение на следующей странице

Таблица 1. Методы прогнозирования. (Продолжение таблицы)

Тип метода	Название	Преимущества	Недостатки	Суть метода	Мат описание
Нейронные сети	GRU	Легче и быстрее LSTM, сохраняет способность захватывать долгосрочные зависимости	Меньше гибкости, не всегда так хорош, как LSTM	Модифицированная RNN, оптимизированная для долгосрочных зависимостей	$h_t = \sigma(W_h \cdot h_{t-1} + W_x \cdot x_t + b_h)$
				Моделирование случайных процессов для оценки вероятности разных сценариев	$P(\theta X) = \frac{P(X \theta)P(\theta)}{P(X)}$

Модель прогнозирования спроса на электроэнергию в энергетических системах, учитывающая краткосрочные и долгосрочные детерминанты спроса, для потребителей со стохастическим паттерном потребления

Стохастические потребители имеют характеристики, которые сильно отличаются от более традиционных, например, потребителей для бытовых нужд или промышленных объектов. Для более точных прогнозов потребности в электроэнергии необходимо учитывать как краткосрочные, так и долгосрочные детерминанты спроса, которые могут значительно варьироваться. Для решения этих задач и повышения точности прогнозирования могут потребоваться гибридные модели, например, комбинация SARIMA XGBOOST и LSTM.

Одним из важных факторов для получения высокой точности модели это правильный выбор детерминант. Потребление энергии электромобилями будет изменяться в зависимости от времени суток. Например, в ночное и вечернее время спрос на энергию обычно возрастает, поскольку это время, когда владельцы электромобилей активно заряжают свои транспортные средства. В модели это можно учесть, добавив соответствующую переменную, которая будет отражать влияние времени суток на потребление энергии. Кроме того, спрос на электроэнергию меняется в зависимости от дня недели. В выходные и праздничные дни, когда люди чаще совершают поездки, потребление электроэнергии может увеличиваться, так как зарядка электромобилей требует больше времени. Это также стоит учитывать, чтобы точно прогнозировать изменения в спросе. Температурные колебания также оказывают влияние на потребление энергии. В холодные месяцы, когда возрастает потребность в отоплении, нагрузка на энергосистему увеличивается. Электромобили в зимний период могут потреблять больше энергии не только для зарядки, но и для обогрева, что необходимо учитывать в прогнозах. Кроме того, важно опираться на исторические данные потребления энергии. Эти данные позволяют выявить закономерности, такие как пики потребления в опре-

деленные периоды времени или изменения, связанные с сезонными факторами, что добавляет точности модели. Наконец, сезонность является важным фактором, который также влияет на потребление электроэнергии. В зимний и летний период наблюдаются различия в уровне потребления, которые должны быть учтены при прогнозировании для более точной оценки будущих потребностей в электроэнергии. Однако при прогнозировании спроса на электроэнергию со стороны электромобилей можно учесть несколько специфичных детерминант, которые напрямую влияют на поведение этих потребителей, можно рассмотреть применимость таких детерминант отдельно для каждой модели.

Математическая модель SARIMA для прогнозирования спроса с учетом этих факторов выглядит следующим образом:

$$\left(1 - \sum_{i=1}^p \phi_i B^i\right) (1 - B^s)^P X_t = \mu + \theta_0 + \sum_{j=1}^q \theta_j B^j \epsilon_{t-j} + \sum_{k=1}^r \beta_k Z_{t-k} + \epsilon_t. \quad (1)$$

Здесь X_t — это наблюдаемое значение потребления энергии в момент времени t , а μ — это среднее значение временного ряда. Члены с суммами θ_j и ϕ_i отвечают за авторегрессию (AR) и скользящее среднее (MA), как в классической модели ARIMA. Однако, для более точного прогнозирования в данной модели учтены дополнительные переменные, отражающие влияющие на спрос факторы. Эти переменные задаются параметрами Z_t . β_k — коэффициенты, отражающие влияние детерминант на конечную переменную.

Одной из очевидных детерминант, влияющих на потребление электромобилей, является трафик (пробки). Однако нужно учитывать, что SARIMA сама по себе ограничена в плане учета сложных факторов, таких как плотность трафика. Модель хорошо справляется с сезонными трендами и историческими данными, но не всегда может адекватно учесть внешние переменные без значительных изменений в её структуре. Поэтому если влияние трафика на потребление энергии

действительно велико, может быть полезно дополнить модель SARIMA более сложными методами, такими как XGBoost или LSTM, которые лучше справляются с учетом нелинейных и экзогенных факторов.

Модель XGBoost представляет собой мощный инструмент машинного обучения, идеально подходящий для прогнозирования спроса на электроэнергию, особенно с учётом множества внешних факторов, таких как стоимость электроэнергии. XGBoost использует метод градиентного бустинга, что позволяет эффективно учитывать нелинейные зависимости и работать с большим количеством признаков. В контексте прогнозирования спроса на электроэнергию со стороны электромобилей, модель может интегрировать множество факторов, таких как стоимость электроэнергии, количество электромобилей, плотность трафика, а также погодные условия.

Математическое выражение модели XGBoost для прогнозирования спроса на электроэнергию с учётом этих факторов выглядит следующим образом:

$$\hat{y}_t = \sum_{i=1}^N \eta_i h_i(X_t) + \beta_1 P_t + \beta_2 Z_t + \beta_3 T_t. \quad (2)$$

В этой формуле $\hat{y}_t$ представляет собой прогнозируемое значение потребления электроэнергии в момент времени t , а η_i — веса для каждого дерева решений. $h_i(X_t)$ — это результат работы каждого дерева для набора входных признаков X_t , которые могут включать множество факторов, влияющих на спрос на электроэнергию. Среди этих факторов ключевое место занимает стоимость электроэнергии P_t , которая непосредственно влияет на поведение пользователей электромобилей. Когда тарифы на электроэнергию высоки, пользователи, как правило, откладывают зарядку своих автомобилей на более поздние часы, что сказывается на динамике потребления в разные периоды времени. Это явление можно учесть в модели XGBoost, добавив стоимость электроэнергии как один из признаков, что позволит точнее

предсказать изменения спроса в зависимости от колебаний цен.

В этой модели так же, как и в SARIMA, необходимо учитывать такие переменные, как время суток, так как зарядка электромобилей чаще всего происходит в вечерние или ночные часы, что приводит к пиковому потреблению энергии в эти временные интервалы. Плотность трафика также важна для учета в этой модели, так как в периоды повышенной активности на дорогах возрастает количество поездок, что увеличивает потребность в зарядке электромобилей с некоторым временным лагом.

Таким образом, модель XGBoost, учитывающая такие факторы, как стоимость электроэнергии, время суток, плотность трафика и температурные условия — позволяет более точно прогнозировать потребление электроэнергии со стороны электромобилей, принимая во внимание как краткосрочные колебания, так и долгосрочные экономические и инфраструктурные тренды.

Модель LSTM (Long Short-Term Memory) является мощным инструментом для работы с временными рядами, поскольку она позволяет учитывать долгосрочные зависимости в данных. Математическое представление модели LSTM описывается через несколько ключевых элементов, таких как забывающий, входной и выходной блоки, которые контролируют информацию, проходящую через модель, и позволяют хранить долгосрочные зависимости. Все эти компоненты работают совместно для обновления состояний модели в каждом временном шаге. Математически модель LSTM можно выразить следующими уравнениями

$$\begin{aligned} f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f); \\ i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i); \\ \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C); \\ C_t &= f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t; \\ o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o); \\ h_t &= o_t \cdot \tanh(C_t). \end{aligned} \quad (3)$$

В этих уравнениях f_t — это забывающий блок,

который решает, какую информацию из предыдущего состояния нужно забыть. i_t – это входной блок, который определяет, какую информацию следует сохранить. $\widetilde{C}_t$ – это кандидат на обновление состояния клетки, а C_t – это обновленное состояние клетки, которое представляет собой долгосрочную память. Выходной блок o_t регулирует, какая информация будет передана в следующее состояние и выходные данные, а h_t представляет собой скрытое состояние модели, которое передает результаты модели на каждом временном шаге. Входные данные x_t включают все факторы, которые влияют на потребление электроэнергии

За счет своей способности сохранять долгосрочные зависимости, модель LSTM может эффективно учитывать сезонные колебания в потреблении энергии и экзогенные факторы, такие как изменения в инфраструктуре зарядных станций или колебания цен на электроэнергию. Это делает LSTM мощным инструментом для прогнозирования энергопотребления электромобилями, особенно в условиях неопределенности, когда традиционные методы не всегда могут учесть все нюансы и факторы, влияющие на потребление.

Объединение различных моделей прогнозирования, таких как SARIMA, XGBoost и LSTM, представляет собой мощный инструмент для более точного прогнозирования спроса на электроэнергию со стороны электромобилей [8]. Каждая из этих моделей имеет свои сильные стороны, и их сочетание позволяет использовать преимущества всех подходов, что ведет к улучшению точности прогноза и учету различных факторов.

Для достижения наивысшей точности и скорости обработки данных наиболее перспективными методами являются взвешенное объединение и ансамблевые методы.

Взвешенное объединение предполагает, что прогнозы каждой модели комбинируются с определенными весами, отражающими их точность. Это может быть записано как:

$$\widehat{y}_{\text{final}} = w_1 \widehat{y}_{\text{SARIMA}} + w_2 \widehat{y}_{\text{XGBoost}} + w_3 \widehat{y}_{\text{LSTM}}. \quad (4)$$

Где w_1 , w_2 , w_3 – веса, определяемые в процессе обучения. Этот метод прост в реализации и может эффективно использовать преимущества каждой модели, обеспечивая высокую точность.

Второй перспективный подход – использование ансамблевых методов, таких как градиентный бустинг или случайный лес, для объединения прогнозов всех моделей. Математически это можно выразить как:

$$\widehat{y}_{\text{final}} = f(\widehat{y}_{\text{SARIMA}}, \widehat{y}_{\text{XGBoost}}, \widehat{y}_{\text{LSTM}}). \quad (5)$$

Где f – ансамблевая модель, обученная на выходных данных всех трех моделей. Этот метод позволяет адаптировать веса моделей в зависимости от их вклада в итоговый прогноз, улучшая точность и скорость обработки.

Эти подходы позволяют эффективно интегрировать различные модели и быстро адаптироваться к изменяющимся данным, обеспечивая высокую точность и устойчивость прогноза в условиях нестабильности на энергорынке.

Заключение

Основной научный результат данной работы заключается в разработке гибридной модели прогнозирования спроса на электроэнергию, которая учитывает стохастические паттерны потребления, характерные для электромобилей. В ходе исследования были предложены методы объединения моделей **SARIMA**, **XGBoost** и **LSTM**, которые обеспечивают точность прогнозов с учетом временных зависимостей, экзогенных факторов и долгосрочных трендов. Эти модели эффективно интегрируют сезонные колебания, влияние внешних факторов, таких как температура и плотность трафика, а также изменяющиеся тарифы на электроэнергию. Особое внимание уделено построению гибридной модели, которая объединяет результаты нескольких методов для повышения точности прогноза.

Научная новизна работы заключается в том, что для прогноза потребления электроэнергии, вызванного развитием стохастических потребителей, предложен новый подход, включающий

использование комбинации статистических методов, машинного обучения и нейронных сетей. Это позволяет более точно моделировать влияние стохастических факторов на энергопотребление и создавать более гибкие и устойчивые стратегии управления энергосистемами. Пред-

ложенная методология может быть использована для повышения эффективности управления нагрузкой в энергосетях, а также для разработки более прогрессивных моделей тарифной политики, что имеет важное значение для адаптации энергетических систем к новым условиям.

Библиографический список

1. ГИБДД России. Показатели состояния безопасности дорожного движения. — URL: <http://stat.gibdd.ru> (дата обр. 10.01.2025).
2. Концепция по развитию производства и использования электрического автомобильного транспорта в Российской Федерации на период до 2030 года. Распоряжение Правительства РФ № 2290-р от 23 августа 2021 г. / Российская Федерация. Правительство. — 2021.
3. Минэнерго России. Приказ № 2328 от 29.11.2024 г. Об утверждении схемы и программы развития электроэнергетических систем России на 2025–2030 годы. — Москва. — 2024. — URL: https://minenergo.gov.ru/upload/iblock/808/Prikaz-ME-ot-29.11.2024-2328-ob-utverzhenii-SiPR-EES-na-2025_2030-PUBLIKATSIYA.pdf.
4. A stochastic short-term scheduling of virtual power plants with electric vehicles under competitive markets / H. Rashidizadeh-Kermani [et al.] // International Journal of Electrical Power & Energy Systems. — 2021. — Jan. — Vol. 124. — P. 106343. — ISSN 0142-0615. — DOI: [10.1016/j.ijepes.2020.106343](https://doi.org/10.1016/j.ijepes.2020.106343).
5. *Almuhaini S. H., Sultana N.* Forecasting Long-Term Electricity Consumption in Saudi Arabia Based on Statistical and Machine Learning Algorithms to Enhance Electric Power Supply Management // *Energies*. — 2023. — Feb. — Vol. 16, no. 4. — P. 2035. — ISSN 1996-1073. — DOI: [10.3390/en16042035](https://doi.org/10.3390/en16042035).
6. Forecasting Chinese Electricity Consumption Based on Grey Seasonal Model with New Information Priority / W. Zhou [et al.] // *Sustainability*. — 2023. — Feb. — Vol. 15, no. 4. — P. 3521. — ISSN 2071-1050. — DOI: [10.3390/su15043521](https://doi.org/10.3390/su15043521).
7. Multiple Novel Decomposition Techniques for Time Series Forecasting: Application to Monthly Forecasting of Electricity Consumption in Pakistan / H. Iftikhar [et al.] // *Energies*. — 2023. — Mar. — Vol. 16, no. 6. — P. 2579. — ISSN 1996-1073. — DOI: [10.3390/en16062579](https://doi.org/10.3390/en16062579).
8. *Paliari I., Karanikola A., Kotsiantis S.* A comparison of the optimized LSTM, XGBOOST and ARIMA in Time Series forecasting // 2021 12th International Conference on Information, Intelligence, Systems & Applications (IISA). — IEEE, 07/2021. — P. 1–7. — DOI: [10.1109/iisa52424.2021.9555520](https://doi.org/10.1109/iisa52424.2021.9555520).
9. *Shklyarskiy J., Batueva D.* The influence of external climatic factors on the accuracy of the forecast of energy consumption // *E3S Web of Conferences* / ed. by N. Vatin, P. Zunino, E. Vdovin. — 2019. — Vol. 140. — P. 04014. — ISSN 2267-1242. — DOI: [10.1051/e3sconf/201914004014](https://doi.org/10.1051/e3sconf/201914004014).