

УДК 004.852:621.311

*Аристархов Н.М.,
студент магистратуры,
1 курс, Институт радиоэлектроники и
информационных технологий
(ИРИТ-РТФ),
Уральский Федеральный Университет
имени первого Президента
России Б.Н. Ельцина,
г. Екатеринбург*

*Харисов А.Р.,
кандидат технических наук,
руководитель образовательной программы
«Системы управления сложными объектами и процессами»,
Уральский Федеральный Университет имени
первого Президента
России Б.Н. Ельцина,
г. Екатеринбург*

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ В ЭНЕРГЕТИКЕ

Аннотация: Современные подходы к прогнозированию энергетических временных рядов с использованием нейронных сетей. Рассмотрены особенности данных (нелинейность, сезонность, влияние внешних факторов) и архитектуры: LSTM, GRU, TCN, Transformer, GNN. Экспериментальное сравнение моделей (MLP, LSTM, TCN, Transformer) для краткосрочного прогнозирования нагрузки показало превосходство глубоких архитектур.

Наиболее эффективными признаны гибридные и attention-модели, обеспечивающие высокую точность к сложным временным зависимостям.

***Ключевые слова:** временные ряды, искусственные нейронные сети, энергетика, прогнозирование нагрузки, LSTM.*

***Annotation:** Modern approaches to forecasting energy time series using neural networks. The features of data (nonlinearity, seasonality, influence of external factors) and architectures are considered: LSTM, GRU, TCN, Transformer, GNN. An experimental comparison of models (MLP, LSTM, TCN, Transformer) for short-term load forecasting showed the superiority of deep architectures. Hybrid and attention-based models are recognized as the most effective, providing high accuracy for complex time dependencies.*

***Key words:** time series, artificial neural networks, energy, and load forecasting, LSTM.*

ВВЕДЕНИЕ

Прогнозирование временных рядов является одной из ключевых задач в электроэнергетике и играет важную роль в процессах оперативного и стратегического управления энергосистемами. Точность прогнозов электрической нагрузки и генерации электроэнергии напрямую влияет на планирование режимов работы электростанций, балансирование спроса и предложения, оптимизацию затрат и обеспечение надёжности энергоснабжения. Современные энергетические системы характеризуются высокой сложностью и динамичностью. На поведение временных рядов электропотребления оказывают влияние многочисленные факторы: погодные условия, сезонность, социально-экономическая активность, календарные эффекты, рост доли распределённой генерации и возобновляемых источников энергии. В результате энергетические временные ряды становятся нелинейными, нестационарными и трудно предсказуемыми с использованием классических статистических методов.

Традиционные подходы к прогнозированию, такие как модели ARIMA, SARIMA и экспоненциальное сглаживание, показывают удовлетворительные результаты лишь при выполнении предположений о стационарности и линейности процессов. В условиях современных энергосистем эти предположения часто нарушаются, что приводит к снижению точности прогнозов. В последние годы искусственные нейронные сети и методы глубокого обучения стали одним из наиболее перспективных инструментов прогнозирования временных рядов в энергетике. Их ключевым преимуществом является способность автоматически выявлять сложные нелинейные зависимости и скрытые закономерности в данных без явного задания модели процесса. Это делает нейросетевые подходы особенно актуальными для задач энергетического прогнозирования.

Целью данной работы является анализ современных нейросетевых методов прогнозирования временных рядов и определение архитектур искусственных нейронных сетей, наиболее подходящих для практических задач энергетики.

2. ОСОБЕННОСТИ ВРЕМЕННЫХ РЯДОВ В ЭНЕРГЕТИКЕ

Временные ряды в энергетике обладают рядом специфических характеристик, существенно отличающих их от временных рядов в других прикладных областях.

Во-первых, энергетические временные ряды демонстрируют многомасштабную сезонность. Как правило, в данных одновременно присутствуют суточные, недельные и годовые циклы. Например, потребление электроэнергии увеличивается в утренние и вечерние часы, отличается в будние и выходные дни, а также зависит от сезона года.

Во-вторых, энергетические данные являются нестационарными. Со временем изменяются средние значения, дисперсия и структура временных зависимостей, что связано с изменением поведения потребителей,

внедрением энергоэффективных технологий и ростом распределённой генерации.

В-третьих, существенную роль играют экзогенные факторы, прежде всего погодные аномалии с резким изменением метеорологических параметров (температура, влажность, солнечная радиация, скорость ветра). Игнорирование этих факторов приводит к значительному ухудшению качества прогнозирования.

Кроме того, энергетические временные ряды часто содержат пропуски и выбросы, вызванные сбоями измерительных приборов и систем передачи данных. Это требует применения устойчивых методов предобработки и обучения моделей.

Указанные особенности делают прогнозирование в энергетике сложной задачей, требующей применения гибких и адаптивных моделей, способных эффективно работать с нелинейными и высокоразмерными данными.

3. КЛАССИЧЕСКИЕ ПОДХОДЫ К ПРОГНОЗИРОВАНИЮ ВРЕМЕННЫХ РЯДОВ

До широкого распространения методов машинного обучения в энергетике доминировали классические статистические модели прогнозирования временных рядов. Наиболее распространёнными из них являются модели семейства ARIMA и SARIMA.

Модель ARIMA основана на линейной зависимости текущего значения временного ряда от его предыдущих значений и ошибок прогноза. Для учёта сезонности используется расширение SARIMA, включающее сезонные авторегрессионные и скользящие компоненты.

Несмотря на простоту и интерпретируемость, данные модели имеют ряд существенных ограничений. Они предполагают стационарность процесса или возможность её достижения путём дифференцирования, а также плохо

справляются с нелинейными зависимостями и мультивариативными данными.

В условиях современных энергосистем, характеризующихся высокой нелинейностью и зависимостью от внешних факторов, классические методы зачастую уступают нейросетевым подходам по точности прогнозирования.

4. ОБЗОР АРХИТЕКТУР ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ

4.1. Полносвязные нейронные сети

Полносвязные нейронные сети (MLP) являются одной из простейших архитектур искусственных нейронных сетей. При применении к временным рядам они используют фиксированное окно исторических данных в качестве входа.

Несмотря на простоту реализации, MLP не учитывают явную временную структуру данных и, как правило, используются лишь в качестве базовых моделей для сравнения.

4.2. Рекуррентные нейронные сети (LSTM, GRU)

Рекуррентные нейронные сети специально разработаны для обработки последовательных данных. Архитектуры LSTM и GRU позволяют эффективно моделировать временные зависимости и решают проблему исчезающего градиента, характерную для классических RNN.

В энергетике LSTM и GRU получили широкое распространение благодаря способности учитывать суточную и недельную динамику нагрузки. Однако рекуррентные сети имеют ограниченные возможности распараллеливания и могут испытывать трудности при моделировании очень долгосрочных зависимостей.

4.3. Temporal Convolutional Networks

Temporal Convolutional Networks со сверточной архитектурой, адаптированные для временных рядов. Использование причинных (causal)

свёрток и дилатаций позволяет TCN моделировать длинные временные зависимости без рекуррентных связей.

TCN обладают рядом преимуществ: стабильность обучения, высокая вычислительная эффективность и возможность параллельной обработки данных. В ряде исследований TCN демонстрируют сопоставимую или лучшую точность по сравнению с LSTM.

4.4. Transformer-ориентированные архитектуры нейронных сетей

Transformer-модели основаны на механизме self-attention (самовнимание), позволяющем учитывать зависимости между любыми моментами времени в последовательности. Для задач временных рядов были разработаны специализированные модификации Transformer, такие как Temporal Fusion Transformer и Informer.

Преимуществами Transformer являются способность моделировать долгосрочные зависимости и гибкость при работе с мультивариативными данными. Основными недостатками остаются высокая вычислительная сложность и требовательность к объёму обучающих данных.

4.5. Графовые нейронные сети

В задачах прогнозирования нагрузки на уровне распределительных сетей важную роль играют пространственные зависимости между узлами. Графовые нейронные сети позволяют учитывать топологию энергосистемы и пространственно-временные корреляции.

Комбинация GNN с временными моделями (LSTM, TCN, Transformer) считается одним из наиболее перспективных направлений развития нейросетевых методов в энергетике.

5. ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ

5.1. Постановка эксперимента

Экспериментальное исследование направлено на сравнительный анализ эффективности различных архитектур искусственных нейронных сетей в

задаче краткосрочного прогнозирования почасовой электрической нагрузки, которая является одной из ключевых прикладных задач в электроэнергетике [1].

В качестве исследуемых моделей были выбраны многослойный перцептрон (MLP), рекуррентная нейронная сеть LSTM, Temporal Convolutional Network (TCN) и Transformer-ориентированная архитектура. Данный набор моделей отражает основные направления развития нейросетевых методов прогнозирования временных рядов, широко представленные в современной научной литературе [1, 3].

5.2. Данные и предобработка

В эксперименте использовались открытые наборы данных по почасовому электропотреблению, аналогичные тем, которые применяются в современных исследованиях по прогнозированию нагрузки в энергетике [1].

Для повышения качества прогнозирования была выполнена стандартная предобработка данных, включающая нормализацию числовых признаков, обработку пропусков и кодирование календарных факторов. Применение таких методов предобработки соответствует рекомендациям обзорных работ по глубокому обучению для временных рядов [3, 5].

5.3. Выбор и описание моделей

Использование рекуррентных нейронных сетей LSTM обусловлено их способностью эффективно моделировать краткосрочные и среднесрочные временные зависимости, что неоднократно подтверждалось в задачах прогнозирования электрической нагрузки [1, 5].

Temporal Convolutional Networks были выбраны в качестве альтернативы рекуррентным архитектурам, поскольку они обеспечивают более стабильное обучение, лучше масштабируются и демонстрируют конкурентоспособные результаты при прогнозировании временных рядов [2].

Transformer-ориентированная модель применялась для анализа эффективности механизмов внимания при выявлении долгосрочных

зависимостей и сложных корреляций между признаками, что соответствует современным тенденциям развития моделей временных рядов [3, 4].

5.4. Метрики оценки качества прогнозирования

Для количественной оценки качества прогнозирования использовались метрики MAE, RMSE и MAPE, которые являются стандартными показателями в исследованиях по прогнозированию электрической нагрузки и широко применяются для сопоставления результатов различных моделей [1].

5.5. Анализ и обсуждение результатов

Полученные результаты экспериментального исследования подтверждают выводы обзорных работ о том, что современные глубокие нейросетевые архитектуры существенно превосходят базовые модели при прогнозировании временных рядов в энергетике [1, 3].

Сопоставимая точность моделей LSTM и TCN согласуется с результатами исследований, в которых сверточные архитектуры временных рядов демонстрируют конкурентоспособность по отношению к рекуррентным нейронным сетям при меньших вычислительных затратах [2].

Преимущество Transformer-модели по показателям точности подтверждает эффективность attention-механизмов для выявления сложных временных зависимостей и корреляций в данных, однако высокая вычислительная сложность таких моделей требует осторожного подхода при их практическом внедрении в энергетических системах [4].

ЗАКЛЮЧЕНИЕ

В данной статье проведён анализ современных подходов к прогнозированию временных рядов в энергетике с использованием искусственных нейронных сетей. Рассмотрены особенности энергетических временных рядов и ограничения классических статистических методов.

Показано, что современные архитектуры глубокого обучения, такие как LSTM, TCN и Transformer, обеспечивают существенный прирост точности прогнозирования. Наиболее перспективными для практического применения в энергетике являются TCN и Transformer-ориентированные модели, а также гибридные архитектуры, сочетающие временное и attention-моделирование.

Полученные результаты подтверждают целесообразность дальнейших исследований в направлении гибридных и пространственно-временных нейросетевых моделей для задач энергетического прогнозирования.

Использованные источники:

1. Vanting N. B., Ma Z., Jørgensen B. N. Обзор применения глубоких нейронных сетей для прогнозирования электрической нагрузки // *Energy Informatics*. 2021. Т. 4. Прил. 2. С. 1–20.
2. Bai S., Kolter J. Z., Koltun V. Эмпирическое сравнение сверточных и рекуррентных нейронных сетей для моделирования последовательностей // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 2018. С. 1–12.
3. Lim B., Zohren S. Прогнозирование временных рядов с использованием глубокого обучения: обзор // *Philosophical Transactions of the Royal Society A*. 2021. Т. 379, № 2194. С. 1–35.
4. Shi J., Zhou Y., Li H. Прогнозирование временных рядов на основе гибридной модели LSTM–Transformer // *Scientific Reports*. 2024. Т. 14, № 1. С. 1–14.
5. Хайкин С. Нейронные сети: полный курс / пер. с англ. 2-е изд. М.: Вильямс, 2006. С. 1104.