



*К.С. Серегичев, А.А. Суконщиков*  
Вологодский государственный университет

## КРАТКОВРЕМЕННОЕ ПРОГНОЗИРОВАНИЕ ЭЛЕКТРОПОТРЕБЛЕНИЯ СОВРЕМЕННЫХ ЭНЕРГОЕМКИХ ПРЕДПРИЯТИЙ

В статье рассматриваются вопросы краткосрочного прогнозирования электропотребления современных предприятий. Исследование проводится с использованием различных моделей нейронных сетей и модели скользящего среднего. Для нейронных сетей используются методы: прогнозирование на один шаг, на несколько шагов сразу, прогнозирование с авторегрессией, прогноз по одному шагу с отправкой выходных данных обратно в модель.

Прогнозирование, нейронные сети, авторегрессия, модель скользящего среднего.

Современные предприятия сырьевого сектора экономики, и в частности предприятия металлургии, относятся к наиболее энергоемким отраслям промышленности РФ. При этом затраты на электроэнергию на них обычно превышают затраты на все прочие энергетические ресурсы, необходимые для производства [1]. В условиях рыночной экономики и постоянного повышения цен на энергоресурсы особую актуальность приобретает задача прогнозирования потребления электроэнергии для более качественного планирования и управления энергохозяйством предприятия.

Отдельно стоит заметить, что кроме очевидной выгоды – снижение доли затрат на электроэнергию в единице готовой продукции за счет более качественного планирования и управления производством, также имеется и другая статья экономии – стоимость электроэнергии на оптовом рынке электроэнергии, которая напрямую зависит от качества планирования ее потребления. Это связано с тем, что некачественное планирование крупным потребителем электроэнергии может вносить существенный дисбаланс в региональную систему производства и распределения электроэнергии, заставляя оперативно менять режимы генерации электроэнергии и схемы ее распределения. Для снижения количества и величины подобных инцидентов на оптовом рынке электроэнергии Системным оператором введен порядок определения цены на мощность [2].

Точность прогнозирования непосредственно связана с методом расчета. Статистические методы и методы искусственного интеллекта в настоящее время являются наиболее перспективными при прогнозировании электрической нагрузки, поскольку имеют ряд преимуществ (в части обеспечения точности прогноза при минимизации затрат ресурсов на решение задачи) в сравнении с традиционными методами, основанны-

ми на использовании детерминированных моделей объекта.

Данные о потреблении электроэнергии представляют собой временные ряды. В данной статье приводятся результаты прогнозирования указанных временных рядов с использованием библиотек TensorFlow и Statsmodels. Используются различные стили моделей, включая SARIMA, сверточные и рекуррентные нейронные сети (CNN и RNN). В качестве набора данных использована только информация о фактическом потреблении электроэнергии предприятием, без использования косвенных и вспомогательных технологических параметров, а также производственных планов. Это обусловлено текущей организационной структурой на предприятии, а также наличием либо отсутствием оцифрованных данных.

Исследование состоит из двух основных частей с подразделами:

1. Прогноз с использованием различных моделей нейронных сетей:

- прогнозирование на один шаг;
- прогнозирование на несколько шагов сразу;
- прогнозирование с авторегрессией. Прогноз по одному шагу с отправкой выходных данных обратно в модель.

2. Прогноз с использованием модели скользящего среднего.

В качестве набора данных для исследования использованы обезличенные результаты почасовых измерений электроэнергии на одном из промышленных предприятий за период в 3 года. Прогнозы будут также иметь почасовую дискретность.

Для начала представим имеющиеся данные в виде графика, а также посмотрим на результаты работы функции автокорреляции (ACF) и функции частичной автокорреляции (PACF). На рисунке 1 показано, что данные не имеют явно выраженных периодичностей.

Стоит отметить, что графики ACF и PACF являются лишь одним из многих инструментов, которые можно использовать для анализа и прогнозирования временных рядов. Другие методы, такие как частотный анализ, также могут быть полезны для понимания закономерностей в данных временных рядов. Определяя задержки и шаблоны в данных, мы можем лучше понять зависимости между временными шагами и построить более точные модели временных рядов.

Далее мы можем определить важные частоты (периодичность данных) с помощью быстрого преобразования Фурье (рис. 2). Обратим внимание на наличие некоторых неявных производственных циклов в рамках рабочего месяца, сменного графика работы и, по всей видимости, производственного плана. Но при этом очевидных пиков нет, чтобы мы могли использовать эти данные в дальнейшем исследовании.

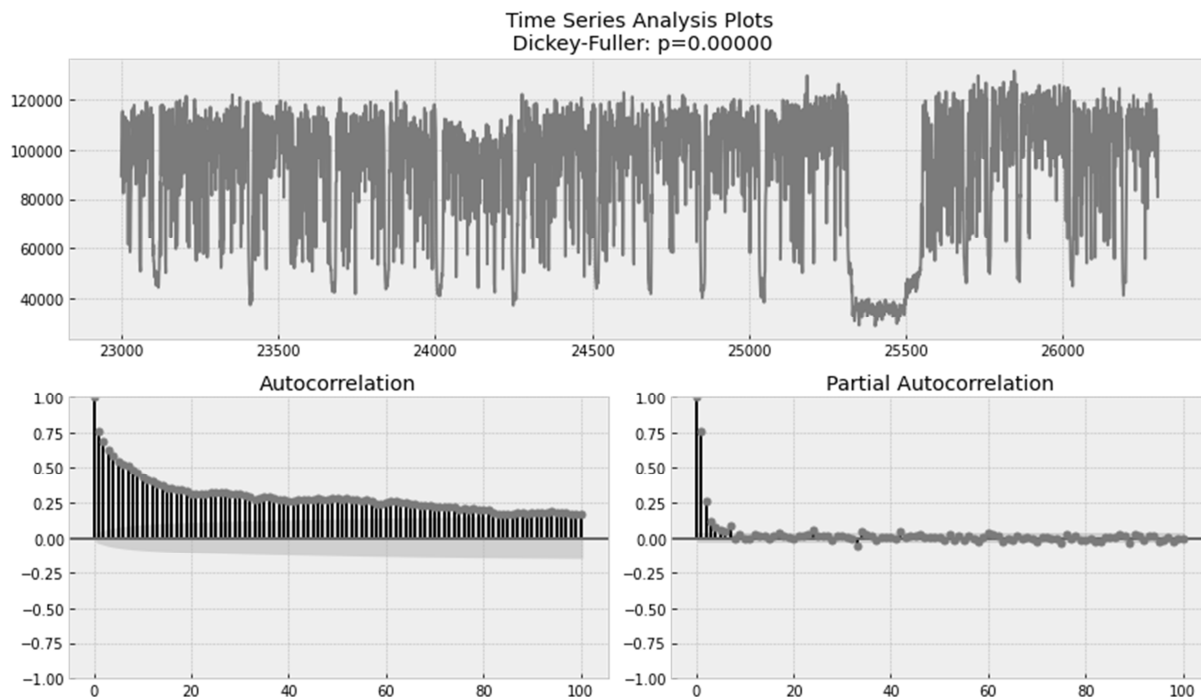


Рис. 1. График набора данных, его ACF и PACF




Рис. 2. График частот после быстрого преобразования Фурье




Рис. 3. Столбчатая диаграмма с данными по средней абсолютной ошибке в % для каждой из используемых моделей с прогнозированием на один шаг

Перед обучением нейронной сети важно масштабировать данные. Нормализация – это распространенный способ масштабирования: вычислять среднее значение и разделить на стандартное отклонение набора данных. Среднее значение и стандартное отклонение следует вычислять только с использованием обучающих данных, чтобы модели не имели доступа к значениям в проверочных и тестовых наборах. Также можно утверждать, что модель не должна иметь доступа к будущим значениям в тренировочном наборе во время обучения и что эта нормализация должна выполняться с использованием скользящих средних.

Выполним прогнозирование на один шаг с использованием линейной модели с одним нейроном без активации (Linear), модели с несколькими скрытыми слоями (Dense), многоступенчатой модели с несколькими скрытыми слоями (Multi step dense), модели сверточной нейронной сети (Conv), модели рекуррентной нейронной сети (LSTM). В качестве базовой модели (Baseline) для оценки производительности мы будем использовать модель, которая делает прогноз «без изменений», используя предыдущее историческое значение. Каждая модель, за исключением первых двух, выполняет прогноз на один час вперед, учитывая шесть часов истории.

Как мы видим на рисунке 3, несмотря на то, что относительно базовой модели есть улучшение по точ-

ности, эти модели совершенно нельзя использовать в практической деятельности. Причина кроется в том, что зависимость крайне сложная для такого маленького «окна» входных данных. В ходе обучения моделей мы заметили, что моделям с небольшим количеством нейронов не хватает внутренних связей для построения столь сложных зависимостей, а значительное увеличение количества нейронов быстро приводит к переобучению модели из-за нехватки вспомогательных данных для обучения.

Далее выполним прогнозирование с использованием тех же моделей, но изменив их (добавив количество нейронов в выходном слое, для предсказания на 24 шага, используя 24 предыдущих исторических значения).

На следующем подэтапе мы усложним наши модели для предсказания последовательности будущих значений.

Есть два общих подхода к этому:

1. Прогнозы на весь диапазон за один проход, когда весь временной ряд прогнозируется сразу.

2. Прогнозы авторегрессии, при которых модель делает только одношаговые прогнозы, а ее выходные данные возвращаются в качестве входных данных.

Для построения модели с авторегрессией (AR LSTM) мы возьмем уже имеющуюся модель LSTM и добавим в нее авторегрессионный цикл обратной связи.

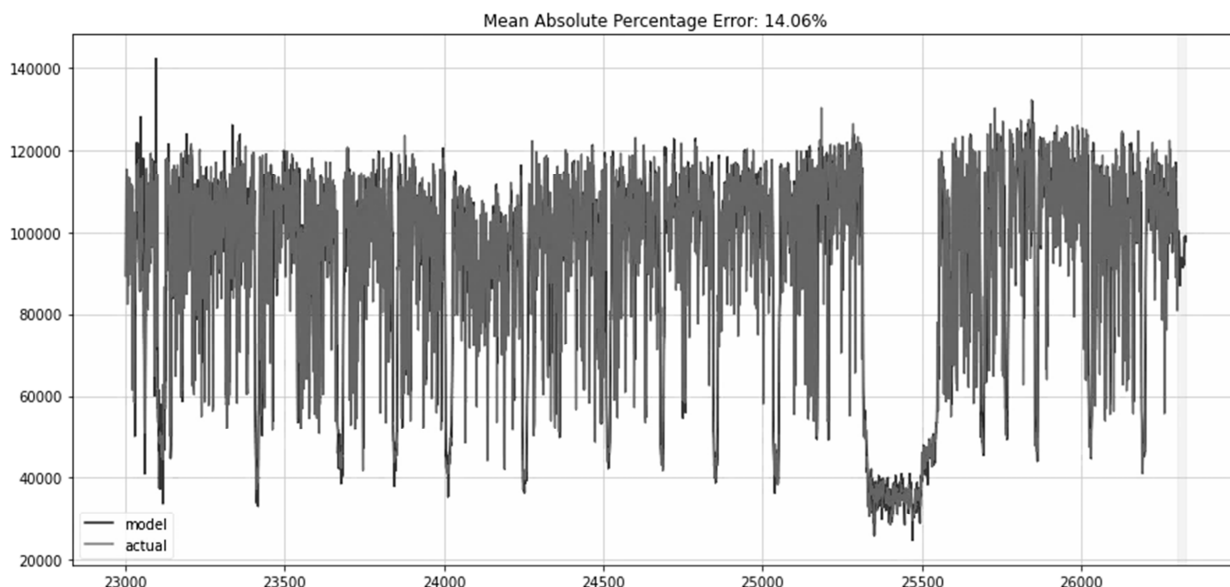


Рис. 4. Графики целевой переменной и предсказания, наложенные друг на друга, с выводом величины ошибки над графиком

Результаты данного этапа с использованием базовых возможностей моделей, основанных на нейронных сетях, показывают их низкую эффективность для решения поставленной задачи и требуют изменения подхода. На следующем этапе мы выполним прогнозирование с использованием модели скользящего среднего SARIMAX (рис. 4).

Для определения наилучших параметров мы, используя метод `statespace` библиотеки `Statsmodels`, циклично проверим весь разумный диапазон комбинаций настроечных параметров модели.

Как мы видим, SARIMAX-модель демонстрирует лучшую точность для решения поставленной задачи. При этом стоит отметить, что данное качество возможно только при должной настройке, что достаточно трудоемко как по вычислительным ресурсам, так и по времени. При этом ее точности все равно недостаточно для использования неспециалистом в качестве готового инструмента прогнозирования, лишь в качестве одного из инструментов поддержки принятия решения.

По результатам проведенного исследования, а также на основании современных исследований как

отечественных, так и зарубежных ученых можно сделать вывод, что дальнейшее исследование и улучшение качества прогноза по данной проблеме возможно. Оно должно быть связано с моделями, которые способны извлекать различные релевантные математические функции из временного ряда и, используя их, выполнять более качественное прогнозирование. В дальнейшем исследовании необходимо использовать релевантные математические функции.

#### Литература

1. Баланс энергоресурсов 2005–2019 гг. – [https://rosstat.gov.ru/storage/mediabank/5RIE0jgu/en\\_balans.htm](https://rosstat.gov.ru/storage/mediabank/5RIE0jgu/en_balans.htm)
2. Планирование потребления на сутки вперед для клиентов энергосбытовой организации. – <https://energo.blog/blog/shemy-postavki/planirovanie-potreblenija/>
3. Прогнозирование временных рядов. – [https://www.tensorflow.org/tutorials/structured\\_data/time\\_series](https://www.tensorflow.org/tutorials/structured_data/time_series)
4. Анализ временных рядов методами пространства состояний. – <https://www.statsmodels.org/dev/statespace.html#seasonal-autoregressive-integrated-moving-average-with-exogenous-regressors-sarimax>.

*K.S. Seregichev, A.A. Sukonshchikov*  
Vologda State University

### SHORT-TERM PREDICTION OF MODERN ENERGY-INTENSIVE ENTERPRISES ELECTRIC CONSUMPTION

The article discusses the issues of short-term forecasting of power consumption of modern enterprises. The research is carried out using various neural network models and a moving average model. For neural networks the following methods are used: forecasting for one step, several steps at once, forecasting with autoregression, forecasting one step at a time with sending the output data back to the model.

Forecasting, neural networks, autoregression, moving average model.