

## **ПРОГНОЗИРОВАНИЕ РЫНОЧНЫХ ЦЕН НА ЭЛЕКТРОЭНЕРГИЮ И ЧАСОВ ПИКОВОЙ НАГРУЗКИ ДЛЯ РЕГИОНА РОССИЙСКОЙ ФЕДЕРАЦИИ**

**Марьясин О. Ю.<sup>1</sup>, Лукашов А. И.<sup>2</sup>  
Смирнов Н. А.<sup>3</sup>**

*(Ярославский государственный технический университет,  
Ярославль)*

*Рассмотрено применение цифровой модели потребителя электроэнергии для анализа и прогнозирования рыночных цен на электроэнергию и часов пиковой нагрузки для Ярославской области Российской Федерации. Для построения цифровой модели энергопотребителя использовался аппарат искусственных нейронных сетей. Данный аппарат обладает широкими возможностями для прогнозирования и позволяет получить необходимую точность прогнозирования почасовых значений рыночных цен на электроэнергию. Приведены результаты численных экспериментов по прогнозированию рыночных цен на электроэнергию с использованием разработанного авторами приложения, в ходе которых исследовалось качество прогноза в зависимости от типа искусственной нейронной сети и ее структуры. Для прогнозирования часов пиковой нагрузки в работе использовался косвенный метод, основанный на прогнозировании на месяц вперед суммарного потребления электроэнергии региона. Приведены результаты численных экспериментов по прогнозированию суммарного энергопотребления региона и часов пиковой нагрузки на месяц вперед. Показано, как можно использовать данные, полученные в результате анализа часов пиковой нагрузки за предыдущие годы для повышения достоверности выполненных прогнозов. Прогнозирование рыночных цен на электроэнергию и часов пиковой нагрузки создает возможности для решения задач оптимального планирования энергопотребления.*

**Ключевые слова:** цена на электроэнергию, час пиковой нагрузки, прогнозирование, искусственная нейронная сеть.

---

<sup>1</sup> *Олег Юрьевич Марьясин, к.т.н., доцент (maryasin2003@list.ru).*

<sup>2</sup> *Андрей Иванович Лукашов, директор инженерингового центра (lukashovai@yustu.ru).*

<sup>3</sup> *Никита Андреевич Смирнов, магистрант (smirnof2bs@mail.ru).*

## 1. Введение

Стратегия цифровой трансформации электроэнергетики России предусматривает использование искусственного интеллекта для детализации и управления энергопотреблением, что позволит выявить возможности экономии электроэнергии с учетом специфики каждого хозяйствующего субъекта или домохозяйства [4]. Это означает, что для каждого потребителя электроэнергии должна быть построена индивидуальная цифровая модель, или «цифровой двойник» энергопотребителя.

Одним из основных применений цифровой модели энергопотребителя (ЦМЭ) должно стать прогнозирование объемов потребления, цен на электроэнергию и других показателей, влияющих на возможность снижения затрат на электроэнергию. Актуальность темы прогнозирования обусловлена необходимостью наличия у хозяйствующих субъектов обоснованных знаний о перспективных уровнях показателей электроэнергии в существующих условиях неопределенности и волатильности прогнозируемых показателей, в целях снижения затрат на электроэнергию и повышения качества планирования своей работы [1].

Другим важным применением ЦМЭ должна стать оптимизация энергопотребления. Данная задача актуальна для предприятий Российской Федерации, рассчитывающихся за электроэнергию по 3–6 ценовым категориям. Для таких предприятий снижение оплаты за электроэнергию можно получить путем:

- учета почасовых рыночных цен на электроэнергию;
- снижения платы за мощность в часы пиковой нагрузки.

В первом случае добиться снижения энергозатрат можно уменьшая потребление электроэнергии в периоды высоких цен и увеличивая нагрузку в часы, когда цена на электроэнергию становится ниже. В Российской Федерации после отмены государственного регулирования цен на электрическую энергию и мощность цена на электроэнергию для потребителей складывается из нерегулируемой составляющей оптового рынка электроэнергии (мощности), регулируемых тарифов на услуги по передаче

электрической энергии, сбытовых надбавок гарантирующих поставщиков и платы за иные услуги, оказание которых является неотъемлемой частью процесса поставки электрической энергии потребителям. Доля нерегулируемой части в конечной стоимости электроэнергии для потребителя зависит от уровня напряжения и максимальной мощности его энергопринимающих устройств. Особенностью розничного рынка электроэнергии для регионов Российской Федерации, относящихся к ценовым зонам, является то, что данные о рыночных ценах текущего месяца становятся известны только после десятого числа следующего месяца. Зная объемы потребления и почасовые значения цен на электроэнергию в будущем месяце, предприятие могло бы так перераспределить свои потребности, чтобы избежать излишних затрат в периоды высоких цен и в результате добиться экономии средств на энергоресурсы. Отсюда вытекает потребность прогнозирования рыночных цен на электроэнергию на месяц вперед.

Во втором случае необходимо максимально сократить потребление электроэнергии в часы пиковой нагрузки. Нерегулируемая часть стоимости электроэнергии включает стоимость мощности, которая в среднем составляет около 35% от суммы затрат на электроэнергию [2]. Стоимость мощности, в зависимости от ценовой категории энергопотребителя, складывается из стоимости покупной (потребленной) и сетевой мощности. Объем покупной мощности определяется как среднее за месяц из значений потребления предприятия в часы пиковой нагрузки для субъекта Российской Федерации, в котором находится предприятие. Для того чтобы снизить стоимость покупной мощности для энергопотребителя, необходимо сократить потребление электроэнергии в часы пиковой нагрузки. Данные о часах пиковой нагрузки текущего месяца также становятся известны только после десятого числа следующего месяца. Если бы энергопотребитель заранее знал часы пиковой нагрузки в предстоящем месяце, он бы имел возможность снизить потребление электроэнергии в данные часы и тем самым уменьшить затраты на оплату электроэнергии. Отсюда становится очевидной актуальность прогнозирования часов

пиковой нагрузки.

Во втором разделе работы описывается современное состояние вопроса. В третьем рассматриваются инструменты, используемые авторами для прогнозирования. Четвертый раздел посвящен вопросам анализа поведения рыночных цен на электроэнергию и часов пиковой нагрузки. В пятом приводятся и обсуждаются результаты, полученные авторами при прогнозировании цен на электроэнергию, а в шестом – прогнозировании часов пиковой нагрузки. В последнем разделе сформулированы общие выводы и рекомендации по применению результатов работы.

## **2. Обзор публикаций по прогнозированию энергопотребления, рыночных цен на электроэнергию и часов пиковой нагрузки**

В мировой научной литературе тема прогнозирования энергопотребления и рыночных цен на электроэнергию представлена очень широко. В некоторых публикациях задачи прогнозирования энергопотребления и цен на электроэнергию решались одновременно. В качестве горизонта предсказания в большинстве рассмотренных публикаций используется прогнозирование на сутки, на неделю или на несколько недель вперед. Прогнозирование энергопотребления и цен на электроэнергию на месяц, несколько месяцев или на год вперед встречается гораздо реже.

Из ранних развернутых обзоров по прогнозированию цен на электроэнергию следует отметить [6]. В данном обзоре рассмотрено 47 статей за период с 1997 по 2006 год и выполнен анализ публикаций на основе следующих основных характеристик: тип модели, горизонт предсказания, используемые входные переменные, используемые методы предварительной обработки данных, результаты прогнозирования. Из недавних обзоров по данной теме можно выделить [19, 20, 24]. В [24], как наиболее объемной из данных работ, рассмотрены научные публикации, индексируемые в наукометрических базах Web of Science (304 публикации) и Scopus (497 публикаций) за 1989–2013 годы. Обзоры [19, 20] хоть и являются относительно новыми, но тоже опираются на работы,

выполненные до 2014 года. Из недавних обзорных работ по прогнозированию энергопотребления зданий следует отметить [26] и [7].

Согласно указанным источникам все методы прогнозирования энергопотребления и рыночных цен на электроэнергию можно разделить на следующие основные группы:

- методы, основанные на мультиагентных и теоретико-игровых моделях, имитирующие поведение агентов на рынке электроэнергии;
- методы на базе имитационных моделей, моделирующие стратегии участников рынка и воздействия важнейших физических и экономических факторов на энергопотребление и цену электроэнергии;
- методы, основанные на анализе временных рядов.

Последнюю группу методов можно разделить на методы, использующие стохастические модели, статистические модели и модели искусственного интеллекта, построенные на базе искусственных нейронных сетей (ИНС).

Согласно [24], при краткосрочном прогнозировании цен на электроэнергию статистические методы и методы на базе искусственного интеллекта показали наилучшие результаты. В [8] указано, что прогнозирование почасовых значений цены существенно осложняется нелинейным поведением и быстрыми изменениями данных. В таких условиях, как утверждается в [8], прогнозирование на базе ИНС является более эффективным подходом по сравнению со статистическими методами. О том, что ИНС обладают лучшими возможностями для моделирования неизвестных законов изменения временных рядов рыночных цен на электроэнергию также отмечено в [25].

Актуальную информацию, посвященную применению различных видов ИНС для прогнозирования цен на электроэнергию можно найти в обзоре [23]. Там рассматриваются такие виды ИНС как многослойный персептрон (Multilayer perceptron — MLP), прямонаправленные нейронные сети (Feed-Forward Neural Networks — FFNN), рекуррентные (Recurrent Neural Networks —

RNN), каскадные (Cascaded), вероятностные (Probabilistic), нечеткие (Fuzzy), а также гибридные подходы, комбинирующие ИНС с другими известными технологиями, такими как фильтр Калмана, хаотическая динамика и вейвлет преобразование.

Проведенный анализ показал, что из всех типов традиционных архитектур ИНС для прогнозирования энергопотребления и цен на электроэнергию чаще всего использовались FFNN и RNN. При этом из всех типов FFNN наиболее популярным для прогнозирования энергопотребления и цен на электроэнергию является MLP. На его долю приходится большая часть публикаций. Пример использования MLP для прогнозирования энергопотребления описан в [17].

В последнее время все более популярными становятся методы глубокого машинного обучения и глубокие нейронные сети (Deep Neural Networks — DNN). Из всех типов DNN, применяемых для прогнозирования энергопотребления и цен на электроэнергию, можно выделить сети долгой краткосрочной памяти (Long Short Term Memory Neural Networks — LSTM NN), управляемые рекуррентные нейроны (Gated Recurrent Unit — GRU) и сверточные нейронные сети (Convolutional Neural Networks — CNN).

Для прогнозирования цен на электроэнергию в работе [12] использовались четыре варианта ИНС: сеть MLP с двумя скрытыми слоями; комбинированная ИНС, включающая LSTM- и MLP-подсети; комбинированная ИНС, включающая GRU- и MLP-подсети, и комбинированная ИНС, включающая две CNN-подсети. Все подсети объединялись с помощью общего выходного слоя. В результате исследования показано, что ИНС на базе MLP, LSTM и GRU дают лучшие по точности результаты прогнозирования по сравнению с известными статистическими моделями и методами машинного обучения. Сеть на базе CNN показала результаты хуже, чем остальные ANN и даже некоторые методы машинного обучения, такие как метод опорных векторов (Support Vector Regression) и XGBoost.

В работе [22] для прогнозирования цен на электроэнергию

также использовались четыре варианта ИНС: MLP, CNN, LSTM и GRU. Рассматривались варианты однослойных и трехслойных сетей MLP, LSTM и GRU. В данной работе сеть GRU показала лучшие по точности результаты прогнозирования по сравнению с другими ИНС. Следующей за ней по точности была LSTM. Сеть CNN так же, как и в предыдущем исследовании, показала худшие результаты по точности и производительности.

Для прогнозирования цен на электроэнергию в работе [11] представлена ИНС, включающая последовательное соединение подсетей CNN и LSTM. Подсеть CNN содержит два одномерных слоя свертки, чередующиеся со слоем пулинга. В результате исследования показано, что предложенная ИНС дает лучшие по точности результаты прогнозирования по сравнению с MLP, CNN, LSTM и известными методами машинного обучения, такими как метод опорных векторов (Support Vector Regression), случайный лес (Random forest) и деревья решений (Decision tree). При этом точность прогнозирования, получаемая с помощью MLP и «чистых» CNN и LSTM практически одинакова.

В работе [10] рассматривается прогнозирование энергопотребления в сети Smart Grid на базе CNN. Представленная сеть CNN включает три одномерных слоя свертки, чередующиеся со слоем пулинга, и полносвязный выходной слой. Результаты расчетов показали, что предложенная ИНС дает лучшие по точности результаты прогнозирования по сравнению с MLP, LSTM и методами машинного обучения: метод опорных векторов, случайный лес и деревья решений. При этом использование LSTM позволяет достичь несколько лучшей точности прогнозирования по сравнению с MLP.

Для прогнозирования энергопотребления в работе [21] предлагается использовать комбинированную ИНС, включающую LSTM- и CNN-подсети. Подсети объединялись с помощью общего полносвязного выходного слоя. CNN-подсеть используется для выявления локальных тенденций изменения нагрузки. LSTM-подсеть используется для фиксации долгосрочных зависимостей. В результате исследования показано, что комбинированная ИНС

дает лучшие по точности результаты прогнозирования по сравнению с «чистыми» CNN и LSTM, вариантом сети из [11] и методами машинного обучения случайный лес и деревья решений. При этом точность прогнозирования, получаемая с помощью «чистых» CNN и LSTM, практически одинакова.

В отличие от задач прогнозирования энергопотребления и цен на электроэнергию задача прогнозирования часов пиковой нагрузки не является популярной для зарубежных исследователей. Это связано со спецификой ценообразования на Российском розничном рынке электроэнергии. В зарубежной литературе можно найти только публикации, посвященные решению близких по характеру задач прогнозирования пиков (максимумов) рыночной цены на электроэнергию (Price spike) и пиков электрической нагрузки. В [9] отмечено, что традиционные методы прогнозирования цен на электроэнергию не могут эффективно прогнозировать пики цен. Поэтому для этих целей используются гибридные техники или сложные нейросетевые комплексы. Так, в [18] для прогнозирования пиков цены на электроэнергию был использован комплекс, состоящий из четырех взаимосвязанных ИНС.

В результате анализа литературных источников авторами принято решение об использовании для построения ЦМЭ аппарата ИНС. Данный аппарат обладает широкими возможностями для прогнозирования и позволяет получить необходимую точность прогнозирования почасовых значений энергопотребления и рыночных цен на электроэнергию. При использовании ИНС в случае необходимости улучшения результатов прогнозирования есть возможность перейти к применению более сложной архитектуры ИНС, более сложной структуры ИНС или более сложных методов обучения ИНС.

### **3. Инструменты для прогнозирования**

Для реализации ЦМЭ авторами было разработано компьютерное приложение на языке Python [15]. Разработанное приложение позволяет существенно упростить взаимодействие пользователя с ЦМЭ за счет использования средств человеко-машинного



интерфейса и визуализации. Основными функциями приложения являются:

- Чтение почасовых цен, объемов энергопотребления и часов пиковой нагрузки за определенный период из базы данных для заданного объекта, категории, мощности и уровня напряжения.
- Статистический анализ выбранного набора данных.
- Построение графиков и диаграмм.
- Подготовка различных наборов данных для обучения ИНС.
- Выполнение функций предварительной обработки и подготовки данных для прогнозирования.
- Создание ИНС заданного типа и структуры.
- Обучение ИНС с отображением информации о результатах обучения.
- Прогнозирование энергопотребления на месяц или день вперед, прогнозирование почасовых рыночных цен на электроэнергию и часов пиковой нагрузки на месяц вперед.
- Отображение результатов прогнозирования в табличном и графическом виде. Расчет стандартных показателей точности прогноза.
- Определение оптимального суточного профиля энергопотребления с учетом заданных ограничений.

Разработанное приложение имеет простой, интуитивно понятный интерфейс. Вид главного окна приложения показан на рис. 1.

В настоящее время к наиболее популярным библиотекам для работы с ИНС на языке Python относятся TensorFlow, Keras, PyTorch, NeuPy, Lasagne, Scikit-Neural Network. Keras, NeuPy, Lasagne и Scikit-Neural Network являются высокоуровневыми библиотеками, основанными на известных платформах глубокого машинного обучения. Keras и NeuPy используют в качестве такой платформы библиотеку TensorFlow. Keras также можно подключить к Theano, на базе которой построены также библиотеки Lasagne и Scikit-Neural Network. Scikit-Neural Network кроме того

использует для своей работы популярную библиотеку машинного обучения Scikit-Learn.

Авторами принято решение использовать для прогнозирования библиотеку Keras. Keras предоставляет в распоряжение пользователю мощный инструмент глубокого машинного обучения. Keras, кроме MLP, обеспечивает поддержку множества нейросетевых архитектур, например, таких как CNN и LSTM. Помимо этого достоинством библиотеки Keras является ее высокая гибкость и возможность существенного ускорения вычислений с большими объемами данных при использовании специальных графических процессоров (Graphics Processing Unit – GPU).

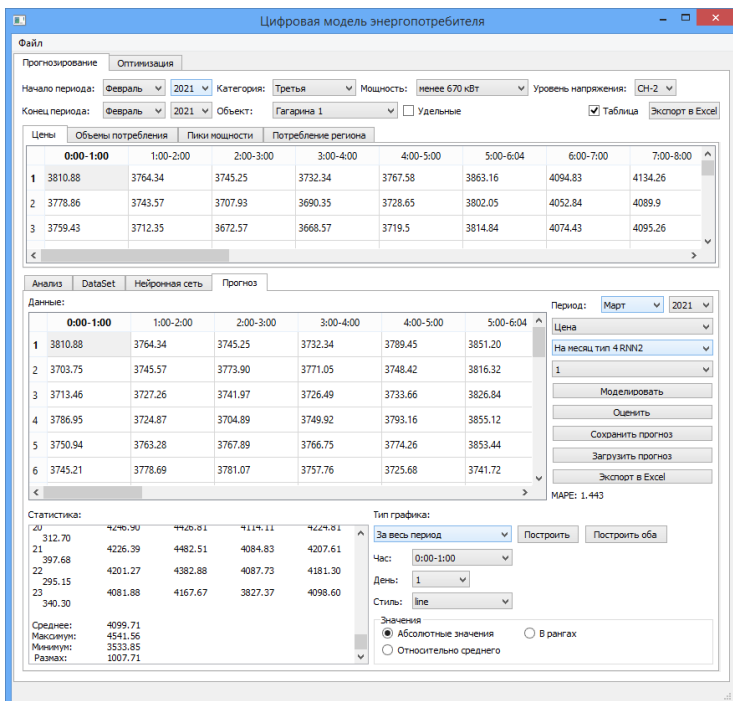


Рис. 1. Вид главного окна приложения

#### **4. Анализ энергопотребления, рыночных цен на электроэнергию и часов пиковой нагрузки**

Как известно, на качество прогнозирования сильно влияют характеристики прогнозируемого временного ряда. Следует отметить, что потребление электроэнергии является индивидуальным для каждого энергопотребителя, а цена на электроэнергию и часы пиковой нагрузки – общими для всего регионального рынка. Это сказывается и на поведении соответствующих временных рядов. Для большинства энергопотребителей потребление электроэнергии имеет, как правило, ярко выраженный суточный и сезонный характер. Во многих случаях, в особенности для энергопотребителей организаций и предприятий, временные ряды почасовых значений энергопотребления имеют схожий, повторяющийся характер. Они значительно различаются только в рабочие и выходные дни.

Авторами был проведен анализ рыночных цен на электроэнергию и часов пиковой нагрузки для Ярославской области Российской Федерации за период с 2016 по 2021 годы. Для анализа использовалась информация о рыночных ценах на электроэнергию в Ярославской области России, публикуемая на сайте ПАО «ТНС энерго Ярославль» [3]. Данные для анализа часов пиковой нагрузки были получены с сайта АО «Администратор торговой системы» [5]. В данной работе показаны обновленные результаты анализа по сравнению с приведенными в [14].

Рыночные цены на электроэнергию имеют сезонный характер и привязаны к текущему календарному месяцу. Анализ цен показал, что характер изменения цены в пределах месяца, положение ее минимумов и максимумов скорее напоминают поведение цены в аналогичный месяц прошлого года, чем в предыдущий месяц того же года. На рис. 2а показан график изменения цены в мае 2020 года, а на рис. 2б – в мае 2021 года. Видно, что на обоих графиках цена ниже в начале месяца, увеличивается к середине месяца и достигает своего максимума в конце месяца.

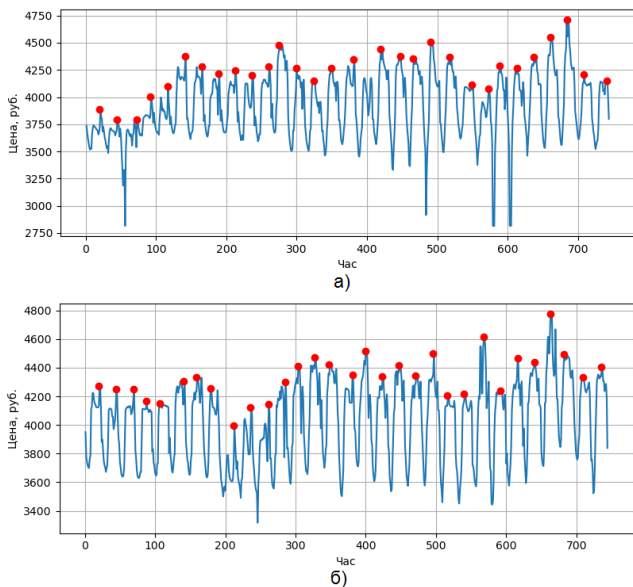


Рис. 2. Графики изменения цены: а) в мае 2020 г.; б) в мае 2021 г.

На рис. 3а показаны гистограммы распределения часов пиковой нагрузки для января и мая 2020 года, на рис. 3б – гистограммы часов пиковой нагрузки для этих же месяцев за 2018, 2019 годы, а на рис. 3в – гистограммы часов пиковой нагрузки для этих же месяцев за весь период с 2016 по 2019 год.

Из рис. 3 можно сделать вывод, что общая картина распределения часов пиковой нагрузки для каждого из месяцев не испытывает серьезных изменений в течение всего рассмотренного периода. В январе пик нагрузки чаще всего приходится на 11 часов до полудня, и эта ситуация не изменяется с 2016 по 2020 год. В мае пик нагрузки чаще всего приходится на 10 часов, и вид распределения также существенно не изменяется за весь рассматриваемый период.

Наиболее часто выпадающие значения часов пиковой нагрузки для каждого месяца и соответствующий процент случаев за 2016–2019 годы и 2016–2020 годы представлены в таблице 1.

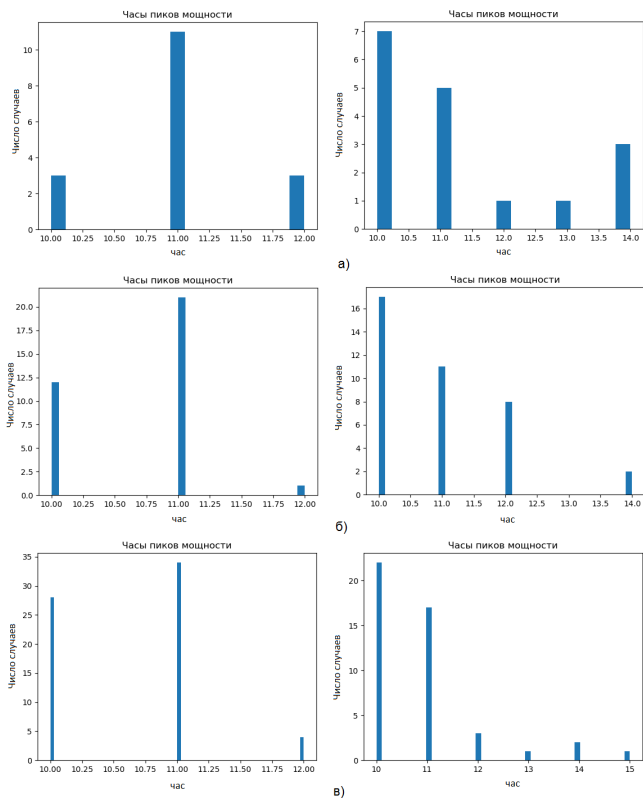


Рис. 3. Гистограммы часов пиковой нагрузки

Используя данные таблицы 1 можно утверждать, что в январе и ноябре более чем в 50 процентов случаев пик нагрузки будет приходиться на 11 часов, а в марте и апреле с такой же степенью вероятности пик нагрузки будет приходиться на 10 часов. Дополнительные данные за 2020 год никак не изменили часа пиковой нагрузки для соответствующего месяца. Изменился только процент случаев, причем он может изменяться как в сторону уменьшения, так и в сторону увеличения.

Кроме распределения часов пиковой нагрузки по месяцам было проанализировано распределение часов пиковой нагрузки по дням недели для каждого месяца. На рис. 4 показаны гисто-

Таблица 1. Наиболее вероятные значения часов пиковой нагрузки по месяцам

Месяц	Час пиковой нагрузки 2016–2019	Процент случаев 2016–2019	Час пиковой нагрузки 2016–2020	Процент случаев 2016–2020
Январь	11	51,52	11	54,22
Февраль	10	63,64	10	58,33
Март	10	67,47	10	61,76
Апрель	10	75	10	70,97
Май	10	49,35	10	47,87
Июнь	11	41,98	11	38,61
Июль	11	47,13	11	39,45
Август	10	34,07	10	31,25
Сентябрь	10	54,76	10	58,49
Октябрь	10	49,44	10	45,05
Ноябрь	11	57,83	11	60,19
Декабрь	10	47,67	10	41,28

граммы распределения часов пиковой нагрузки по дням недели для мая месяца за 2016–2019 годы, а на рис. 5 – гистограммы распределения часов пиковой нагрузки по дням недели для этого же месяца за 2016–2020 годы.

Рис. 4 и 5 показывают, что для одного и того же дня недели пик нагрузки в течение месяца может приходиться на разные часы. Например, во вторник пики нагрузки случались в 10, 11, 12 и 14 часов. При этом с наибольшей вероятностью пик может произойти в 10 часов. Наиболее часто выпадающие значения часов пиковой нагрузки за 2016–2020 годы для каждого месяца по дням недели представлены в таблице 2. В скобках указан соответствующий процент случаев.

Используя данные таблицы 2 можно, например, утверждать, что в феврале и марте с большой вероятностью во вторник и четверг пик нагрузки придется на 10 часов. Таким образом, проведенный анализ позволяет выявить не только наиболее вероятные часы пиковой нагрузки для каждого месяца, но и установить, как часы пиковой нагрузки могут распределяться по дням недели.




Рис. 4. Гистограммы часов пиковой нагрузки по дням недели для мая месяца за 2016–2019 годы

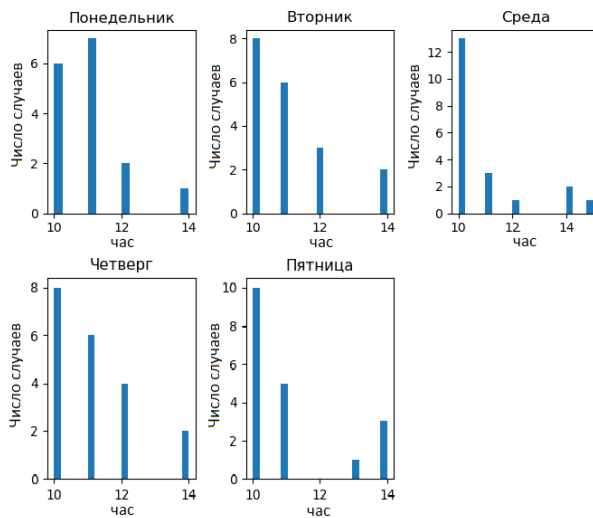


Рис. 5. Гистограммы часов пиковой нагрузки по дням недели для мая месяца за 2016–2020 годы

Таблица 2. Наиболее вероятные значения часов пиковой нагрузки по месяцам и дням недели

Месяц	Пн.	Вт.	Ср.	Чт.	Пт.
Январь	11 (50)	10,11 (47,1)	10,11 (47,1)	11 (64,7)	11 (62,5)
Февраль	10 (47,4)	10 (73,5)	11 (50)	10 (78,9)	10 (50)
Март	10 (44,4)	10 (75)	10 (52,4)	10 (77,3)	10 (57,1)
Апрель	10 (57,9)	10 (73,7)	10 (72,2)	10 (77,8)	10 (72,2)
Май	11 (43,8)	10 (42,1)	10 (65)	10 (40)	10 (52,6)
Июнь	11 (33,3)	11 (45)	10 (47,4)	11 (40,9)	11 (47,6)
Июль	11 (34,7)	11 (40,9)	11 (38,1)	11 (33,3)	11 (50)
Август	11 (31,8)	10 (36,4)	11,14 (26,1)	10,11 (34,7)	10 (40,9)
Сентябрь	11 (42,8)	10 (71,4)	10 (61,9)	10 (61,9)	10 (68,2)
Октябрь	11 (52,2)	10 (56,5)	10 (59,1)	11 (45,5)	11 (52,4)
Ноябрь	11 (55,6)	11 (66,7)	11 (57,1)	11 (59,1)	11 (61,9)
Декабрь	11 (47,6)	10 (45,5)	10 (42,9)	11 (59,1)	10 (59,1)

## 5. Прогнозирование цен на электроэнергию

Наборы данных для прогнозирования цен на электроэнергию формировались в зависимости от типа используемой ИНС. Например, наборы данных для прогнозирования с помощью MLP включали следующие основные признаки: час, день, день недели, месяц, год, данные о ценах или энергопотреблении в прошедшие моменты времени. Значения задержек в часах (lags), выбирались по результатам корреляционного анализа и литературным данным [16]. В результате были выбраны значения задержек  $l \in L = \{1, 2, 3, 24, 48, 168\}$ .



Как было отмечено ранее, изменение рыночной цены на электроэнергию в пределах месяца имеет сезонный характер и привязано к текущему календарному месяцу. Поэтому в наборах данных для прогнозирования рыночной цены на электроэнергию объединялись данные о ценах за предыдущие месяцы текущего года с данными о ценах за тот же месяц предыдущего года, для которого выполнялось прогнозирование.

С помощью разработанной ЦМЭ авторы провели множество численных экспериментов по прогнозированию цен на электроэнергию. В ходе экспериментов исследовалась качество прогноза в зависимости от выбранных входных наборов данных, типа и структуры ИНС, используемых алгоритмов обучения, числа циклов обучения и других факторов. Результаты прогнозирования проверялись как на существующих данных, так и на реальных данных, которые были получены в следующем месяце. Для оценки результатов прогнозирования использовался известный показатель MAPE (Mean Absolute Percentage Error). В данной работе MAPE рассчитывался так же, как в [16].

На рис. 6 показаны результаты прогнозирования почасовой рыночной цены для мая 2021 года. Сплошной линией на рис. 6 показаны реальные значения цены, а пунктирной линией – прогнозируемые значения. Значение MAPE для данного прогноза составило 4,54. Прогнозирование производилось на базе MLP с двумя скрытыми слоями с 20 нейронами в первом слое и 5 нейронами во втором слое. Как было показано в [13] такая структура ИНС близка к оптимальной, при которой обеспечивается минимум значения показателя MAPE.

В [13] прогнозирование цен на электроэнергию производилось на базе MLP. В [15] кроме MLP для прогнозирования рыночных цен на электроэнергию также применялись LSTM и GRU. В данной работе к упомянутым ранее нейросетевым архитектурам были добавлены CNN, а также комбинации MLP с LSTM и CNN.

Сети LSTM и GRU – это разновидности архитектуры RNN. Поскольку RNN удобны для обработки временных последова-

тельностью, то эти сети были применены в первую очередь. В таблице 3 приведены значения MAPE, полученные при прогнозировании цен на электроэнергию для MLP и различных вариантов RNN для шести месяцев 2021 года. Значения MAPE определялись в результате усреднения по результатам десяти прогонов прогнозирования для каждого варианта ИНС.




Рис. 6. Графики реальных и прогнозируемых цен для мая 2021 года

Таблица 3. Результаты прогнозирования для MLP и различных вариантов RNN для шести месяцев 2021 года

Месяц	MLP	LSTM	Multi-input LSTM	GRU	LSTM+MLP
Март	3,15	2,32	2,3	2,42	2,43
Апрель	4,17	3,59	3,56	3,46	3,62
Май	4,27	4,42	4,26	4,49	4,28
Июнь	5,74	5,19	4,2	5,1	5,4
Июль	5,85	4,63	4,56	4,57	4,39
Август	6,62	4,0	3,01	3,68	3,08

При прогнозировании с LSTM и GRU ИНС из временного ряда значений цены для определенного набора данных выделялись подпоследовательности длиной  $n + 1$ , где  $n = 4, 8, 12$ . Значение  $n$  выбиралось так, чтобы число часов в сутках (24) нацело делилось на  $n$ . Первые  $n$  значений подпоследовательности подавались на вход ИНС, а последнее значение – на выход. Структура LSTM и GRU ИНС включала только один скрытый слой с 60 ней-

ронами. В [15] было показано что добавление дополнительного числа нейронов или дополнительного слоя не приводит к увеличению точности прогнозирования. Входные наборы данных для многовходового варианта (Multi-Input) MILSTM ИНС формировались аналогично, за исключением того, что на входы ИНС вместе со значением цены подавались соответствующие календарные данные (час, день, день недели, месяц, год).

Вариант LSTM+MLP представляет собой комбинированную ИНС, включающей LSTM и MLP подсети, объединенные общим MLP слоем. Входной набор данных для этого варианта состоит из двух отдельных наборов данных – набора данных для LSTM и набора данных для MLP. Обе подсети функционируют параллельно, а данные с выходов подсетей объединяются с помощью общего выходного слоя.

Данные таблицы 3 позволяют сказать, что в целом при прогнозировании рыночных цен на электроэнергию, использование RNN позволяет достичь несколько лучшей точности прогнозирования по сравнению с MLP. Повышение точности за счет использования RNN составляет в среднем 20–27%. Из всех вариантов рекуррентных ИНС наиболее предпочтительным оказался многовходовой вариант MILSTM.

Сети CNN также могут быть использованы для обработки временных последовательностей. Из всех видов CNN для обработки временных последовательностей чаще всего используются одномерные (1D) CNN. Для обработки параллельных серий временных последовательностей могут использоваться традиционные двумерные (2D) CNN. В таблице 4 приведены значения MAPE, полученные при прогнозировании цен на электроэнергию для различных вариантов CNN, а также комбинаций CNN с MLP для шести месяцев 2021 года. Как и ранее, значения MAPE усреднялись по результатам десяти прогонов прогнозирования для каждого месяца.

Варианты CNN1 и CNN2 представляют собой 1D CNN. 1D CNN включает слой свертки с ядром, один слой пулинга (используется пулинг с функцией максимума MaxPooling1D),

Таблица 4. Результаты прогнозирования для различных вариантов CNN для шести месяцев 2021 года

Месяц	CNN1	CNN2	CNN3	CNN1+ MLP	CNN2+ MLP
Март	2,49	2,57	2,64	2,27	2,25
Апрель	3,51	3,71	3,86	3,41	3,28
Май	4,46	4,32	4,37	4,21	4,13
Июнь	5,11	5,36	4,63	5,05	4,95
Июль	4,93	5,28	4,71	4,34	4,73
Август	3,97	3,7	3,37	3,54	3,84

выравнивающий слой (Flatten) и выходной слой с одним нейроном. Входные наборы данных для ИНС CNN1 формировались так же, как и для сети LSTM с длиной подпоследовательностей  $n + 1$ , где  $n = 8, 12$ . Одномерный входной шаблон, составленный из  $n$  значений подпоследовательностей подавался на вход ИНС, а последнее значение подпоследовательности подавалось на выход. Для ИНС CNN2 входные наборы данных формировались так же, как и для MLP ИНС. Здесь одномерный входной шаблон, включал все данные подаваемые на вход MLP для конкретного момента времени. Вариант CNN3 представляет собой 2D CNN. 2D CNN содержит слой свертки с ядром  $2 \times 2$ , слой пулинга (используется пулинг MaxPooling2D), выравнивающий слой (Flatten) и полносвязную MLP подсеть, включающую один скрытый слой и выходной слой с одним нейроном. Поскольку CNN3 обрабатывает двумерные массивы (матрицы) данных, то входные наборы данных для этого варианта формировались так же, как и для сети MILSTM.

Вариант CNN1+MLP представляет собой комбинированную ИНС, включающую CNN1 и MLP подсети, объединенные общим MLP-слоем. Входной набор данных для этого варианта состоит из двух отдельных наборов данных – набора данных для MLP и набора данных для CNN1. Обе подсети функционируют параллельно, а данные с выходов подсетей объединяются с помощью общего MLP-слоя. Вариант CNN2+MLP также представляет собой комбинированную ИНС и отличается от предыдущего

варианта только видом входного набора данных.

Данные таблицы 4 позволяют сказать, что в целом использование различных типов CNN, а также комбинаций CNN с MLP также позволяет достичь лучшей точности прогнозирования по сравнению с MLP. Повышение точности за счет использования CNN меньше, чем в предыдущем случае, и составляет в среднем 16–24%. При этом из всех вариантов, рассмотренных в таблице 4, наиболее предпочтительным оказался вариант комбинированной ИНС CNN2+MLP.

Как видно из таблиц 3 и 4, увеличение точности прогнозирования, достигаемое при применении глубоких ИНС, таких как LSTM и CNN, а также их комбинаций, не является слишком значительным. Это также подтверждается существующими литературными данными [11]. Авторы не исключают, что существуют такие варианты DNN, которые позволят достичь более высокой точности прогнозирования. Однако на сегодняшний день самым массовым типом ИНС, применяемым при прогнозировании энергопотребления и рыночных цен на электроэнергию, остаются MLP.

## **6. Прогнозирование часов пиковой нагрузки**

Для прогнозирования часов пиковой нагрузки в данной работе используется косвенный метод, основанный на прогнозировании на месяц вперед суммарного потребления электроэнергии региона. Было установлено, что месячные значения часов пиковой нагрузки, полученные в [5], совпадают со значениями, соответствующими пикам графика суммарного фактического потребления электроэнергии для того же месяца. Следовательно, выполнив прогнозирование суммарного потребления электроэнергии региона на месяц вперед и определив по прогнозу пики потребления за каждые сутки, можно найти значения часов пиковой нагрузки в следующем месяце. Точность прогнозирования часов пиковой нагрузки таким косвенным методом будет зависеть от точности прогнозирования суммарного потребления электроэнергии.

Наборы данных для прогнозирования суммарного потребления электроэнергии региона включали те же признаки, что и наборы данных для прогнозирования цен на электроэнергию за исключением того, что вместо значений цен использовались соответствующие значения суммарного энергопотребления.

Суммарное потребление электроэнергии региона также имеет сезонный характер и привязано к текущему календарному месяцу. Это учитывалось при выполнении прогнозирования суммарного энергопотребления региона. Поэтому в наборах данных объединялись данные о суммарном энергопотреблении за тот же месяц предыдущего года, для которого выполняется прогнозирование, с данными о суммарном энергопотреблении за предыдущие месяцы текущего года.

Рассмотрим прогнозирование часов пиковой нагрузки на примере двух месяцев 2021 года. На рис. 7 показаны графики реального суммарного потребления электроэнергии региона и прогноза суммарного потребления электроэнергии для марта 2021 года. Точность прогнозирования суммарного энергопотребления составила 3,43 MAPE.




Рис. 7. Графики реального суммарного потребления электроэнергии региона и прогноза для марта 2021 года

В [14] прогнозирование часов пиковой нагрузки производилось на базе MLP. В данной работе кроме MLP для прогнозирования часов пиковой нагрузки также применялись LSTM и CNN. В таблице 5 показаны реальные значения и результаты прогнози-

рования часов пиковой нагрузки в марте 2021 года для различных типов ИНС. Ячейки, для которых реальное значение и значение, полученное в результате прогноза, совпадают, выделены цветом. Процент совпадения составляет 27–36% для разных типов ИНС. Такая невысокая степень совпадения объясняется тем, что относительно высокая точность прогнозирования суммарного потребления электроэнергии региона еще не гарантирует точного прогнозирования часов пиковой нагрузки.

Таблица 5. Результаты прогнозирования ЧПН в марте 2021 года для различных типов ИНС

Дата	День недели	ЧПН, реальный	ЧПН, MLP	ЧПН, LSTM	ЧПН, CNN
01.03.21	Пн.	11	12	11	11
02.03.21	Вт.	10	12	10	11
03.03.21	Ср.	11	11	10	11
04.03.21	Чт.	10	11	11	11
05.03.21	Пт.	10	11	11	11
09.03.21	Вт.	10	11	11	11
10.03.21	Ср.	10	11	11	11
11.03.21	Чт.	10	11	11	11
12.03.21	Пт.	11	10	12	10
15.03.21	Пн.	12	11	11	11
16.03.21	Вт.	10	11	11	11
17.03.21	Ср.	10	11	11	10
18.03.21	Чт.	10	11	11	11
19.03.21	Пт.	10	11	11	11
22.03.21	Пн.	11	11	11	11
23.03.21	Вт.	10	10	10	10
24.03.21	Ср.	10	10	10	10
25.03.21	Чт.	10	11	11	11
26.03.21	Пт.	10	11	11	11
29.03.21	Пн.	10	10	11	10
30.03.21	Вт.	10	10	10	10
31.03.21	Ср.	11	10	11	10

Для улучшения качества прогноза воспользуемся результатами анализа часов пиковой нагрузки из раздела 4. Из таблицы 2 видно, что с высокой степенью вероятности в марте во вторник

и четверг час пиковой нагрузки будет приходиться на 10 часов. Скорректируем результаты прогнозирования с учетом данной закономерности. Реальные и скорректированные значения часов пиковой нагрузки показаны в таблице 6. В результате коррекции процент совпадений увеличился до 59–68% для разных типов ИНС.

Таблица 6. Скорректированный прогноз ЧПН в марте 2021 года для различных типов ИНС

Дата	День недели	ЧПН, реальный	ЧПН, MLP	ЧПН, LSTM	ЧПН, CNN
01.03.21	Пон.	11	12	11	11
02.03.21	Вт.	10	10	10	10
03.03.21	Ср.	11	11	10	11
04.03.21	Чт.	10	10	10	10
05.03.21	Пт.	10	11	11	11
09.03.21	Вт.	10	10	10	10
10.03.21	Ср.	10	11	11	11
11.03.21	Чт.	10	10	10	10
12.03.21	Пт.	11	10	12	10
15.03.21	Пн.	12	11	11	11
16.03.21	Вт.	10	10	10	10
17.03.21	Ср.	10	11	11	10
18.03.21	Чт.	10	10	10	10
19.03.21	Пт.	10	11	11	11
22.03.21	Пн.	11	11	11	11
23.03.21	Вт.	10	10	10	10
24.03.21	Ср.	10	10	10	10
25.03.21	Чт.	10	10	10	10
26.03.21	Пт.	10	11	11	11
29.03.21	Пн.	10	10	11	10
30.03.21	Вт.	10	10	10	10
31.03.21	Ср.	11	10	11	10

Теперь рассмотрим прогнозирование часов пиковой нагрузки для мая 2021 года. На рис. 8 показаны графики реального суммарного потребления электроэнергии региона и прогноза суммарного потребления электроэнергии для мая 2021 года. Точность прогнозирования суммарного энергопотребления составила 3,84 MAPE.






Рис. 8. Графики реального суммарного потребления электроэнергии региона и прогноза для мая 2021 года

В таблице 7 показаны реальные значения и результаты прогнозирования часов пиковой нагрузки в мае 2021 года для различных типов ИНС. Процент совпадения составляет 21–37% для разных типов ИНС.

Таблица 7. Результаты прогнозирования ЧПН в мае 2021 года для различных типов ИНС

Дата	День недели	ЧПН, реальный	ЧПН, MLP	ЧПН, LSTM	ЧПН, CNN
04.05.21	Вт.	15	16	15	16
05.05.21	Ср.	11	16	11	11
06.05.21	Чт.	15	11	16	16
07.05.21	Пт.	11	11	11	11
11.05.21	Вт.	10	10	10	10
12.05.21	Ср.	10	11	11	10
13.05.21	Чт.	14	11	15	10
14.05.21	Пт.	11	12	12	10
17.05.21	Пн.	15	16	16	10
18.05.21	Вт.	15	14	16	16
19.05.21	Ср.	15	14	16	10
20.05.21	Чт.	15	16	16	10
21.05.21	Пт.	10	11	10	11
24.05.21	Пн.	15	11	10	10
25.05.21	Вт.	10	11	11	10
26.05.21	Ср.	11	11	11	10
27.05.21	Чт.	15	10	15	10
28.05.21	Пт.	11	11	10	10
31.05.21	Пн.	10	11	11	11

Скорректируем результаты прогнозирования с учетом того, что в мае, в среду и пятницу с высокой степенью вероятности час пиковой нагрузки будет приходиться на 10 часов. Кроме того, учтем, что в предыдущие годы в мае час пиковой нагрузки никогда не попадал на 16 часов. Значит, это значение маловероятно. Реальные и скорректированные значения часов пиковой нагрузки показаны в таблице 8. В результате коррекции процент совпадений увеличился до 32–58%. При этом необходимо учитывать, что коррекция может как улучшить, так и ухудшить прогноз.

Таблица 8. Скорректированный прогноз ЧПН в мае 2021 года для различных типов ИНС

Дата	День недели	ЧПН, реальный	ЧПН, MLP	ЧПН, LSTM	ЧПН, CNN
04.05.21	Вт.	15	15	15	15
05.05.21	Ср.	11	15	11	11
06.05.21	Чт.	15	11	15	15
07.05.21	Пт.	11	10	10	10
11.05.21	Вт.	10	10	10	10
12.05.21	Ср.	10	10	10	10
13.05.21	Чт.	14	11	15	10
14.05.21	Пт.	11	10	10	10
17.05.21	Пн.	15	15	15	10
18.05.21	Вт.	15	14	15	15
19.05.21	Ср.	15	14	15	10
20.05.21	Чт.	15	15	15	10
21.05.21	Пт.	10	10	10	10
24.05.21	Пн.	15	11	10	10
25.05.21	Вт.	10	11	11	10
26.05.21	Ср.	11	10	10	10
27.05.21	Чт.	15	10	15	10
28.05.21	Пт.	11	10	10	10
31.05.21	Пн.	10	11	11	11

Процент совпадений можно значительно увеличить, если вместо одночасового интервала для пиковой нагрузки рассматривать двухчасовой интервал. Расширение интервала для пиковой нагрузки позволяет увеличить вероятность того, что реальный час пиковой нагрузки попадет в расширенный интервал. Увели-

чение интервала можно производить в сторону наиболее вероятного соседнего значения, полученного по результатам анализа данных. Например, если в пятницу 07.05.2021 скорректированный прогноз дает значение часа пиковой нагрузки 10 часов, то соседнее наиболее вероятное значение в мае (рис. 5) будет 11 часов. Следовательно, расширенный двухчасовой интервал для 07.05.2021 будет с 10 до 12 часов.

В таблице 9 показаны реальные значения и скорректированные результаты прогнозирования часов пиковой нагрузки в мае 2021 года для MLP ИНС, а также часы начала и окончания расширенного двухчасового интервала. ИНС MLP была выбрана так как она дала наихудшие результаты прогнозирования часов пиковой нагрузки из всех других типов ИНС.

Таблица 9. Скорректированный прогноз ЧПН в мае 2021 года для MLP и 2-х часовой интервал

Дата	День недели	ЧПН, реальный	ЧПН, MLP	2-х час. интервал
04.05.21	Вт.	15	15	14,15
05.05.21	Ср.	11	15	14,15
06.05.21	Чт.	15	11	10,11
07.05.21	Пт.	11	10	10,11
11.05.21	Вт.	10	10	10,11
12.05.21	Ср.	10	10	10,11
13.05.21	Чт.	14	11	10,11
14.05.21	Пт.	11	10	10,11
17.05.21	Пн.	15	15	14,15
18.05.21	Вт.	15	14	14,15
19.05.21	Ср.	15	14	14,15
20.05.21	Чт.	15	15	14,15
21.05.21	Пт.	10	10	10,11
24.05.21	Пн.	15	11	10,11
25.05.21	Вт.	10	11	10,11
26.05.21	Ср.	11	10	10,11
27.05.21	Чт.	15	10	10,11
28.05.21	Пт.	11	10	10,11
31.05.21	Пн.	10	11	10,11

Как видно из таблицы 9, процент совпадений для двухча-

сового интервала составляет примерно 74%. Таким образом, если бы энергопотребитель имел возможность снизить потребление электроэнергии в период прогнозируемого часа пиковой нагрузки не на один час, а хотя бы на два часа, то это повысило бы вероятность совпадения с реальным часом пиковой нагрузки до 70 и более процентов.

## **7. Выводы**

В работе рассмотрено применение ЦМЭ для анализа и прогнозирования энергопотребления, рыночных цен на электроэнергию и часов пиковой мощности для Ярославской области Российской Федерации. Авторы провели анализ литературных источников с целью определения наиболее популярных методов прогнозирования энергопотребления и цен на электроэнергию, а также наиболее часто используемых при прогнозировании типов ИНС. В работе приведены результаты численных экспериментов по прогнозированию рыночных цен на электроэнергию с использованием разработанного авторами приложения, в ходе которых исследовалось качество прогноза в зависимости от типа ИНС и ее структуры.

Для прогнозирования часов пиковой нагрузки в работе использовался косвенный метод, основанный на прогнозировании на месяц вперед суммарного потребления электроэнергии региона. В работе приведены результаты численных экспериментов по прогнозированию суммарного энергопотребления региона и часов пиковой нагрузки на месяц вперед. Также в работе показано, как можно использовать данные, полученные в результате анализа часов пиковой нагрузки за предыдущие годы для повышения достоверности выполненных прогнозов. Это позволяет обеспечить совпадение скорректированного прогноза с реальными данными на уровне около 50%, а при использовании прогнозируемых двухчасовых интервалов – довести точность прогнозов до уровня 70% и выше.

Необходимо учитывать, что точность прогнозирования рыночных цен на электроэнергию или часов пиковой нагрузки

с использованием ИНС будет зависеть от динамики спроса и предложения на рынке электроэнергии, зависящей от множества факторов. При этом возможны резкие изменения уровня данных факторов от их среднестатистических значений в предыдущие периоды времени. Это может быть, например, резкое изменение цены на топливо. Так как в топливном балансе ОЭС Центра, к которой относится Ярославская область, большую часть занимают ТЭС, работающие на газовом топливе, то резкое изменение цены на газ окажет значительное влияние на стоимость вырабатываемой электроэнергии. Если такое событие произойдет в течение месяца, для которого выполняется прогнозирование, то это может привести к существенному ухудшению качества прогнозирования. Учет таких ситуаций выходит за рамки данной статьи.

Опробованная в работе возможность прогнозирования часов пиковой нагрузки может дать большой практический эффект по снижению энергозатрат, при выполнении мер по уменьшению энергопотребления в периоды времени, включающие часы пиковой нагрузки. Это может быть актуально для производств, технологические процессы которых имеют инерционный характер и допускают возможность снижения энергопотребления в течение одного или двух часов без заметных изменений качества выпускаемой продукции. Снижение энергопотребления в часы пиковой нагрузки также возможно за счет реорганизации профиля энергопотребления предприятия, подключения возобновляемых источников энергии (солнечных панелей, ветрогенераторов) или других местных генераторов и накопителей энергии.

Как было сказано во введении, стоимость мощности в среднем составляет около 35% от общей стоимости электроэнергии для предприятий, рассчитывающихся за электроэнергию по 3–6 ценовым категориям. Стоимость мощности рассчитывается как произведение средневзвешенной рыночной цены на мощность на среднее энергопотребление предприятия в часы пиковой нагрузки за текущий месяц. Если предприятие сократит энергопотребление в часы пиковой нагрузки в течение месяца хотя бы в два раза, то это даст ему получить экономию около 15%.

Полное сокращение энергопотребления в часы пиковой нагрузки позволит довести экономию примерно до уровня 30% от общей стоимости электроэнергии для потребителей.

### Литература

1. ЗОЛотова И.Ю., Дворкин В.В. *Краткосрочное прогнозирование цен на российском оптовом рынке электроэнергии на основе нейронных сетей* // Проблемы прогнозирования. – 2017. – №6. – С. 47–57.
2. *Стоимость мощности электроэнергии – Инструкция от А до Я*. [Электронный ресурс]. – URL: <https://energo-audit.com/tsena-moshchnosti-elktroenergii> (дата обращения: 20.01.2022).
3. *Цены на электроэнергию «ТНС энерго Ярославль»*. [Электронный ресурс]. – URL: <https://yar.tns-e.ru/legal-entities/prices> (дата обращения: 20.01.2022).
4. *Цифровая трансформация электроэнергетики России*. [Электронный ресурс]. – URL: <https://www.digital-energy.ru/wp-content/uploads/2020/04/strategiya-tsifrovoy-transformatsii-elektroenergetiki.pdf> (дата обращения: 20.01.2022).
5. *Часы пиковой нагрузки АО «АТС»*. [Электронный ресурс]. – URL: <https://www.atsenergo.ru/results/market/calcfacthour> (дата обращения: 20.01.2022).
6. AGGARWAL S.K., SAINI L.M., KUMAR A. *Electricity price forecasting in deregulated markets: A review and evaluation* // Electrical Power and Energy Systems. – 2009. – Vol. 31. – P. 13–22.
7. AMBER K.P., AHMAD R., ASLAM M.W., KOUSAR A., USMAN M., KHAN M.S. *Intelligent techniques for forecasting electricity consumption of buildings* // Energy. – 2018. – Vol. 157. – P. 886–893.
8. AMJADY N., HEMMATI M. *Energy price forecasting problems and proposals for such predictions* // IEEE Power and Energy Magazine. – 2006. – Vol. 4(2). – P. 20–29.

9. AMJADY N., KEYNIA F. *A new prediction strategy for price spike forecasting of day-ahead electricity markets* // Applied Soft Computing. – 2011. – Vol. 11. – P. 4246–4256.
10. KUO P., HUANG C. *A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting* // Energies. – 2018. – Vol. 11(213). – P. 1–13.
11. KUO P., HUANG C. *An Electricity Price Forecasting Model by Hybrid Structured Deep Neural Networks* // Sustainability. – 2018. – Vol. 10. – P. 1–17.
12. LAGO J., DE RIDDER F., DE SCHUTTER B. *Forecasting spot electricity prices: deep learning approaches and empirical comparison of traditional algorithms* // Applied Energy. – 2018. – Vol. 221. – P. 386–405.
13. MARYASIN O.YU., LUKASHOV A.I. *A Python Application for Hourly Electricity Prices Forecasting Using Neural Networks* // Int. Russian Automation Conference. – 2020. – P. 138–143.
14. MARYASIN O.YU., LUKASHOV A.I. *Analyzing and Forecasting Peak Load Hours* // Int. Conf. on Industrial Engineering, Applications and Manufacturing. – 2021. – P. 25–30.
15. MARYASIN O.YU., LUKASHOV A.I. *Developing a Digital Model of an Electricity Consumer using Deep Learning* // 2nd Int. Conf. on Control Systems, Mathematical Modeling, Automation and Energy Efficiency. – 2020. – P. 624–629.
16. RANJBAR M., SOLEYMANI S., SADATI M., RANJBAR A.M. *Electricity Price Forecasting Using Artificial Neural Network* // Int. Conf. on Power Electronics, Drives and Energy Systems. – 2006. – P. 1–6.
17. SALAHAT S., AWAD M. *Short-term forecasting of electricity consumption in Palestine using artificial neural networks* // Int. Journal of Artificial Intelligence and Applications. – 2017. – Vol. 8, No. 2. – P. 11–21.

18. SANDHU H.S., FANG L., GUAN L. *Forecasting day-ahead price spikes for the Ontario electricity market* // Electric Power Systems Research. – 2016. – Vol. 141. – P. 450–459.
19. SINGH N., MOHANTY S.R. *A Review of Price Forecasting Problem and Techniques in Deregulated Electricity Markets* // Journal of Power and Energy Engineering. – 2015. – Vol. 3. – P. 1–19.
20. SINGH N., MOHANTY S.R., MISHRA K.K., NERI F. *A Review of Electricity Price Forecasting Problem and Techniques in Deregulated Markets* // Int. Journal of Economics and Statistics. – 2017. – Vol. 5. – P. 101–112.
21. TIAN C., MA J., ZHANG C., ZHAN P. *A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network* // Energies. – 2018. – Vol. 11. – P. 1–13.
22. UGURLU U., OKSUZ I., TAS O. *Electricity Price Forecasting Using Recurrent Neural Networks* // Energies. – 2018. – Vol. 11(1225). – P. 1–23.
23. VIJAYALAKSHMI S., GIRISH G.P. *Artificial Neural Networks for Spot Electricity Price Forecasting: A Review* // Int. Journal of Energy Economics and Policy. – 2015. – Vol. 5(4). – P. 1092–1097.
24. WERON R. *Electricity price forecasting: A review of the state-of-the-art with a look into the future* // Int. Journal of Forecasting. – 2014. – Vol. 30 (4). – P. 1030–1081.
25. ZHANG J., TAN Z., YANG S. *Day-ahead electricity price forecasting by a new hybrid method* // Computers and Industrial Engineering. – 2012. – Vol. 63. – P. 695–701.
26. ZHAO H., MAGOULES F. *A review on the prediction of building energy consumption* // Renewable and Sustainable Energy Reviews. – 2012. – Vol. 16. – P. 3586–3592.



## MARKET ELECTRICITY PRICES AND PEAK LOAD HOURS FORECASTING FOR A REGION OF THE RUSSIAN FEDERATION

**Oleg Maryasin**, Yaroslavl State Technical University, Yaroslavl, PhD in technique, associate professor (maryasin2003@list.ru).

**Andrey Lukashov**, Yaroslavl State Technical University, Yaroslavl, engineering center director (lukashovai@ystu.ru).

**Nikita Smirnov**, Yaroslavl State Technical University, Yaroslavl, student (smirnof2bs@mail.ru).

*Abstract: The article considers the use of a digital model of an electricity consumer for the analysis and forecasting of market electricity prices and peak load hours for the Yaroslavl region of the Russian Federation. To build a digital model of an electricity consumer, the apparatus of artificial neural networks was used. This apparatus has a wide range of forecasting capabilities and allows researchers to obtain the required forecasting accuracy hourly values of market electricity prices. The results of numerical experiments on forecasting market electricity prices using the application developed by the authors are presented. In the course of numerical experiments, the quality of the forecast was studied depending on the type of artificial neural network and its structure. To forecast peak load hours, we used an indirect method based on forecasting of the total electricity consumption of the region. The results of numerical experiments on forecasting the total energy consumption of the region and peak load hours for the month ahead are presented. The article shows how the data obtained from the analysis of peak load hours for previous years can be used to improve the reliability of the forecasts made. Forecasting market electricity prices and peak load hours creates opportunities for solving problems of optimal energy scheduling.*

Keywords: electricity price, peak load hour, forecasting, artificial neural network.

УДК 004.94

ББК 31.281

DOI: 10.25728/ubs.2022.99.4

*Статья представлена к публикации членом редакционной коллегии Я.И. Квинто.*

*Поступила в редакцию 07.03.2022.*

*Дата опубликования 30.09.2022.*