

Прикладная эконометрика, 2020, т. 60, с. 5–25.

Applied Econometrics, 2020, v. 60, pp. 5–25.

DOI: 10.22394/1993-7601-2020-60-5-25

А. М. Лозинская, А. Ю. Редькина, Е. А. Шенкман¹

Прогнозирование электропотребления объединенной энергосистемы: учет сезонных колебаний

В работе построен среднесрочный прогноз потребления электроэнергии для отдельных регионов ОЭС Урала на месячных данных с января 2008 по сентябрь 2019 г. Особенностью работы является применение линейных комбинаций прогнозов, сконструированных на базовых моделях временных рядов, учитывающих как детерминированную, так и стохастическую сезонности. Предложенная методология демонстрирует высокое качество прогноза, устойчивое к горизонту прогнозирования (в сравнении с базовыми моделями и бенчмарком), и может быть использована различными игроками рынка электроэнергии.

Ключевые слова: оптовый рынок электроэнергетики; прогнозирование электропотребления; детерминированная сезонность; стохастическая сезонность.

JEL classification: C53; Q47.

1. Введение

Невозможно представить себе современную цивилизацию без использования электроэнергии. Электроэнергетика входит в десятку отраслей с наибольшим вкладом в ВВП России (2.6% в 2016 г.). Объемы потребляемой энергии ежегодно растут — спрос на электроэнергию по прогнозам Минэнерго в среднем будет увеличиваться ежегодно на 1%². Рост спроса обусловлен как экстенсивными факторами (увеличением численности населения и ростом экономики некоторых регионов), так и интенсивными — появлением новых технологий. Вместе с тем в настоящее время продолжает действовать федеральный закон об энергосбережении РФ³, одной из целей которого является снижение потребления

¹ Лозинская Агата Максимовна — Национальный исследовательский университет «Высшая школа экономики», Пермь; alozinskaia@hse.ru.

Редькина Анастасия Юрьевна — Национальный исследовательский университет «Высшая школа экономики», Пермь; aredkina@hse.ru.

Шенкман Евгения Андреевна — Национальный исследовательский университет «Высшая школа экономики», Пермь; ea_porova@hse.ru.

² Аналитический обзор «Обзор электроэнергетической отрасли России» за 2018 г. <https://ru.investinrussia.com/data/file/EY-power-market-russia-2018.pdf>.

³ Федеральный закон от 23.11.2009 № 261-ФЗ «Об энергосбережении и о повышении энергетической эффективности, и о внесении изменений в отдельные законодательные акты Российской Федерации» (редакция от 26.07.2019).

электроэнергии. В этих условиях прогнозирование спроса на электроэнергию становится сложной задачей.

Прогнозирование спроса на электроэнергию осуществляется на разных уровнях Единой энергетической системы России: и на уровне объединенных энергетических систем (ОЭС), и на уровне отдельных регионов. Это необходимо в первую очередь для обеспечения надежной работы энергетической системы в целом и непрерывной поставки электричества конечному потребителю. Значительные ошибки прогноза могут привести к авариям в энергетической системе. Они выражаются в перебоях поставки электроэнергии конечным пользователям, в том числе и потребителям «первой категории надежности». Отсутствие бесперерывного режима работы последних может привести «к угрозе жизни и здоровья людей, угрозе безопасности государства, значительному материальному ущербу, расстройству сложного технологического процесса, нарушению функционирования особо важных элементов коммунального хозяйства, объектов связи и телевидения»⁴. Кроме того, перебои влекут за собой серьезные финансовые последствия как для отдельных хозяйствующих субъектов (например, ремонт оборудования, затраты на возобновление подачи и др.), так и для электроэнергетического рынка в целом. Таким образом, построение прогноза спроса является не только сложной, но и крайне важной задачей. Однако ее универсального решения для разных макрорегионов до сих пор не найдено.

В данной работе построен среднесрочный прогноз потребления электроэнергии по предложенному авторами унифицированному алгоритму для нескольких регионов России. Особенностью этого алгоритма является построение прогноза на основе регрессионных моделей, учитывающих как детерминированную, так и стохастическую сезонности, характерные для электропотребления (Abosedra et al., 2009; Wang et al., 2012; Abledu, 2013). Он также включает сравнительный анализ предсказательной силы широкого класса статистических моделей и линейных комбинаций прогнозов для поиска подхода, обеспечивающего минимальную ошибку прогнозирования, в том числе для разных горизонтов (от 1 месяца до 1 года вперед). Насколько известно авторам, ранее при построении среднесрочного прогноза комбинации моделей с разными типами сезонности не применялись.

Методика построения прогноза апробирована на данных электропотребления регионов объединенной энергосистемы Урала (ОЭС Урала). В нее входят Пермский край, Башкортостан, Удмуртия, Свердловская, Челябинская, Оренбургская, Кировская, Курганская области, а также Тюменская область вместе с прилегающими территориями. В отличие от аналогичных исследований энергетической системы России (Доманов, Билалова, 2014; Бурковский и др., 2015), в настоящей работе объектом прогнозирования является сразу несколько регионов, для каждого из которых построенный прогноз демонстрирует высокое качество.

Структура работы выглядит следующим образом. Второй раздел посвящен вопросам прогнозирования электропотребления для разных временных горизонтов, в нем также проведен обзор существующих статистических подходов моделирования сезонности в электропотреблении. В третьем разделе описана структура имеющихся данных, в четвертом — представлена методология прогнозирования электропотребления. Далее идет раздел с описанием эмпирических результатов и заключение.

⁴ Правила устройства электроустановок (ПУЭ), издание седьмое (утверждено приказом Министерства энергетики Российской Федерации от 8 июля 2002 г. № 204).

2. Обзор литературы

2.1. Прогнозирование электропотребления в российской энергетике

На оптовом рынке электроэнергии задача прогнозирования решается на разных временных горизонтах: краткосрочном, среднесрочном и долгосрочном. *Краткосрочными прогнозами* считаются прогнозы на час, сутки или неделю вперед, они строятся, соответственно, на часовых, суточных или недельных данных (Pappas et al., 2008; Zhang et al., 2017). *Долгосрочные прогнозы* строятся, как правило, на несколько лет вперед (Cho et al., 2015). Для российского рынка энергетики стандартными являются прогнозы на 3, 5, 7 лет вперед для оценки «перспективного развития» (Пилениекс, 2018). Такие прогнозы используются для осуществления региональной политики в области энергетики, определения расположения новых мощностей или косвенной оценки уровня экономической активности. Ярким примером важности долгосрочных прогнозов является оценка спроса на электроэнергию, которая была произведена в 2007 г. при подготовке финального этапа реорганизации РАО ЕЭС и планировании развития отрасли на 2008–2015 гг. Низкое качество прогноза — прогнозное значение показателя оказалось выше фактического в 1.4 раза (1482 млрд кВт·ч против 1050 млрд кВт·ч) — привело к тому, что в настоящее время существует избыток мощностей⁵.

Среднесрочные прогнозы строятся, как правило, на срок от одного месяца до одного года вперед (Сао, Wu, 2016; Guo et al., 2018). На российском рынке энергетики среднесрочное прогнозирование на интервале от одного месяца до одного года называется «планированием электроэнергетического режима» (Пилениекс, 2018). Прогнозированием электропотребления на таком временном горизонте занимаются как крупные промышленные предприятия, так и государственные ведомства (регуляторы). Предприятия используют подобные прогнозы для решений по техническому обслуживанию оборудования или заключения сделок по продажам топлива и электроэнергии.

Задача прогнозирования электропотребления Единой энергетической системы России (ЕЭС) на среднесрочном временном горизонте актуальна, во-первых, для Системного оператора (СО) ЕЭС, во-вторых, для Федеральной службы по тарифам (ФСТ) России. На основании этих прогнозов СО производит планирование необходимых объемов выработки электроэнергии и согласование планов ремонта линий электропередач и генерирующего оборудования, которые формируются на год вперед. ФСТ необходимо прогнозировать потребление электроэнергии на календарный год при составлении сводного прогнозного баланса электроэнергии. В соответствии с приказом ФСТ № 53-э/1 от 12 апреля 2012 г. сводный прогнозный баланс формируется на год вперед и необходим в том числе для установления регулируемых цен на рынке электроэнергии (например, тарифов для населения)⁶. Кроме того, прогноз потребления необходим для построения тарифной сетки. Не так давно Правительство заявило о намерении ввести нормы энергопотребления: при превышении «потолка» будет действовать повышенный тариф (Дзагуто и др., 2018). В случае введения

⁵ Бюллетень социально-экономического кризиса в России «Динамика потребления электроэнергии как индикатор экономической активности». Февраль, 2016 г. <http://ac.gov.ru/files/publication/a/7945.pdf>.

⁶ Приложение 1 к приказу ФСТ № 53-э/1 от 12 апреля 2012 г. «Об утверждении порядка формирования сводного прогнозного баланса производства и поставок электрической энергии (мощности) в рамках единой энергетической системы России...»

этого правила недостаточно точный прогноз потребления приведет к неверному определению нормы энергопотребления, что в свою очередь может привести к завышенным ценам на электроэнергию. Поэтому конечные потребители тоже заинтересованы в точном прогнозе, ведь от этого зависят их расходы на товар первой необходимости.

Отметим, что и для СО, и для ФСТ важной является задача прогнозирования не только по ЕЭС, но и по территориальным энергетическим системам. Для ФСТ прогнозирование потребления в региональном разрезе закреплено нормативно — она формирует сводный прогнозный баланс отдельно по субъектам РФ в соответствии с приказом ФСТ № 53-э/1 от 12 апреля 2012 г. СО при прогнозировании электропотребления руководствуется принципом увязки «снизу-вверх» (Антонов, Лукина, 2013), а именно, сначала прогноз осуществляется на уровне субъектов, затем их агрегируют до уровня ОЭС, а потом и до уровня ЕЭС⁷.

2.2. Моделирование сезонности в электропотреблении

Статистические данные электропотребления демонстрируют сезонные колебания в течение года (сезонность), в них также заметна недельная и суточная цикличности (Макоклюев, 2008; Ожегов, Попова, 2017). Сезонные флуктуации электропотребления были обнаружены не только в России (Макоклюев, 2008), но и в европейских странах, например, Бельгии, Финляндии, Франции, Великобритании, Ирландии, Португалии, Италии, Норвегии, Испании, Швеции (Taylor, McSharry, 2007). Они в основном обусловлены сезонными изменениями температуры окружающей среды, продолжительности светового дня и степени облачности (Cho et al., 2013; Гордиенко и др., 2019). Ожидание сезонности также является самостоятельным фактором, который может как провоцировать сезонные флуктуации, так и усиливать их проявление (Пильник и др., 2015).

В зависимости от характера сезонности выделяют детерминированную и стохастическую сезонности. Когда сезонные волны повторяются год от года и предсказуемы, то такая *сезонность называется детерминированной*, и она моделируется регулярной компонентой временного ряда. В случае, когда сезонные волны примерно повторяются год от года, но могут эволюционировать с течением времени (Hunt et al., 2003), имеет место *стохастическая сезонность*, которая частично предсказуема. Стохастическая сезонность относится к нерегулярной компоненте временного ряда. Эволюция сезонных волн более характерна для длинных временных периодов (Пильник и др., 2015).

Для определения характера сезонности в электропотреблении обычно отталкиваются либо от теоретических соображений, либо от эмпирических. Однако из-за того, что на потребление влияет множество факторов (Соловьева, Дзюба, 2013), а также с течением времени меняется структура энергобаланса отдельных регионов (Макоклюев и др., 2019), эмпирически подтвердить детерминированную сезонность практически невозможно. По этой причине для построения прогноза, как правило, применяются модели и детерминированной, и стохастической сезонности (Wang et al., 2012).

⁷ Данный подход прогнозирования законодательно зафиксирован приказом Министерства энергетики РФ № 91 от 11 февраля 2019 г. «Об утверждении требований к прогнозированию потребления и формированию балансов электрической энергии и мощности энергосистемы на календарный год и периоды в пределах года».

При моделировании сезонности используют два основных подхода. Первый подход предполагает удаление из исходного временного ряда потребления сезонной компоненты, т. е. декомпозицию временного ряда и построение модели прогноза электропотребления для сезонно-скорректированного ряда. Такой подход применяется для моделирования детерминированной сезонности. Для проведения декомпозиции ряда используются различные алгоритмы сезонной корректировки, например, метод Census (Shiskin et al., 1967; Shiskin, 1978). Такое десезонирование данных может привести к появлению разного рода искажений в сезонно-скорректированном временном ряде (Пильник и др., 2015), включая порождение ложных сигналов при мониторинге экономической ситуации (Бессонов, Петров, 2013).

В рамках второго подхода для описания сезонности сама модель прогноза электропотребления строится так, чтобы учесть сезонность. Используя этот подход, учесть детерминированную сезонность можно двумя основными способами. Первый заключается во включении в уравнение регрессии фиктивных переменных на каждый сезон. Второй способ — применение периодических тригонометрических функций (полиномов Фурье) в качестве регрессоров (Soares, Medeiros, 2008) или для корректировки ошибок (Clements et al., 2016). В соответствии с (Harvey, 2006), оцененные этими двумя способами сезонные закономерности практически полностью совпадают.

Для моделирования стохастической сезонности чаще всего используют обобщения ARIMA моделей Бокса–Дженкинса. Одним из таких обобщений является модель SARIMA (Seasonal Autoregressive Integrated Moving Average Models), в которой сезонность учитывается путем включения в уравнение регрессии сезонных AR и/или MA компонент таких порядков, чтобы отразить характер сезонной волны (Box et al., 2008). Этот подход демонстрирует хорошую прогнозную силу на месячных данных электропотребления как отдельных городов, так и отдельных стран (Pappas et al., 2008; Abosedra et al., 2009; Abledu, 2013). По этой причине SARIMA модели нашли широкое применение как в академических исследованиях, так и в практических приложениях на протяжении последних десятилетий (Chen, Wang, 2007).

Для учета эволюционирующего характера сезонной компоненты в экономических задачах (Broszkiewicz-Suwaj et al., 2004) чаще применяются PAR модели (Periodic Autoregressive Models). Их отличительной особенностью является моделирование электропотребления с помощью ARIMA подхода для каждого сезона отдельно. Такие модели также содержат сезонные AR и/или MA компоненты, однако оценки коэффициентов перед ними могут быть различными для разных сезонов каждого года. Например, электропотребление в сентябре, когда, как правило, по всей стране начинается отопительный сезон, может характеризоваться трендом, отличным от трендов других месяцев. Этот подход был успешно применен в работе (Maceira, Damázio, 2006) на месячных данных энергосистемы Бразилии, а также в (Espinoza et al., 2005) на более частотных данных для краткосрочного прогнозирования электропотребления Бельгии.

Чаще всего лучшее прогнозное качество демонстрируют не отдельные модели, а линейная комбинация прогнозов (Xiao et al., 2016; Nowotarski et al., 2016; Chou, Tran, 2018). При этом исходные прогнозы могут быть получены разными методами, в том числе с использованием моделей, учитывающих как детерминированную, так и стохастическую сезонности. Возможно, улучшение качества связано с тем, что отдельные модели объясняют только «свои» закономерности в данных, а линейная комбинация

аккумулирует их все (Xiao et al., 2016). Это было проиллюстрировано на данных электропотребления Китая (Wang et al., 2012). Аналогичный подход применяется и в данной работе.

3. Данные

В данном исследовании решается задача прогнозирования спроса на электроэнергию регионов ОЭС Урала. К ОЭС Урала (см. рис. 1) относятся 9 регионов: Пермский край; Свердловская, Челябинская, Оренбургская, Кировская и Курганская области; объединенный регион из Тюменской области, Хакасии, Ханты-Мансийского автономного округа — Югры и Ямало-Ненецкого автономного округа⁸; республика Башкортостан и Удмуртская республика. В работе исследуется только один макрорегион по двум основным причинам. Во-первых, управление каждой ОЭС осуществляется единым оперативным диспетчерским управлением, одной из задач которого является построение среднесрочных и долгосрочных прогнозов. Во-вторых, все регионы внутри каждой ОЭС характеризуются преимущественно схожей структурой энергобаланса, но есть отличия между структурами энергобаланса макрорегионов. Так, отличительной особенностью ОЭС Урала является значительная доля потребления электроэнергии промышленным производством. Поэтому для каждой ОЭС необходимо строить разные прогнозные модели.




Рис. 1. Карта регионов ОЭС Урала

Для проведения исследования были собраны ежемесячные данные фактического суммарного электропотребления (тыс. МВт·ч) для регионов ОЭС Урала за период с января 2008 по сентябрь 2019 г. Данные собраны с сайта НП Совет рынка (<http://ais.np-sr.ru/ru/iasen/index.htm>). Динамика электропотребления для каждого региона за весь период наблюдения представлена на рис. 2.

Можно заметить, что масштаб энергопотребления регионов существенно различается, например, показатели Кировской области и Тюменской области с прилегающими территориями отличаются на порядок. Для выявления сезонных закономерностей региональное

⁸ Далее в тексте будем называть этот объединенный регион Тюменской областью с прилегающими территориями.




Рис. 2. Потребление электроэнергии регионов ОЭС Урала с января 2008 по сентябрь 2019 г. (в тыс. МВт·ч)

потребление электроэнергии было нормализовано. Для каждого региона i нормализованное потребление рассчитывается следующим образом:

$$C_{i,t}^N = \frac{C_{i,t} - \bar{C}_i}{\sigma(C_{i,t})}, \quad (1)$$

где $C_{i,t}$ — потребление в регионе i в месяц t ; $\bar{C}_i$ — среднее арифметическое потребление за весь период наблюдений в том же регионе; $\sigma(C_{i,t})$ — выборочное стандартное отклонение регионального потребления электроэнергии.

Как видно из формулы (1), показатель нормализованного потребления $C_{i,t}^N$ является безразмерным, что позволяет провести сравнение между регионами.

Для выявления цикла сезонности для нормализованных рядов потребления по регионам строятся периодограммы, т. е. эмпирические оценки спектральных плотностей рядов. Для разных регионов периодограммы нормализованного ряда электропотребления оказались практически идентичными, поэтому на графике (рис. 3) отображено среднее значение спектральной оценки плотности по регионам. По периодограмме можно определить число циклов сезонности анализируемого ряда данных, а также длины соответствующих циклов. Как видно из рис. 3, в данных электропотребления присутствует один ярко выраженный цикл (одна гармоника) с частотой 0.083, что соответствует длине цикла 12 месяцев. Это означает, что в данных потребления электроэнергии каждого региона присутствует «несинусоидальный цикл» длиной 12 месяцев. Следовательно, при моделировании сезонности в модели




Рис. 3. Периодограмма среднего по регионам нормализованного потребления электроэнергии

необходимо либо включить фиктивные переменные на каждый месяц цикла, либо моделировать тенденции отдельно для каждого месяца в течение года.

С целью выявления особенностей поведения ряда внутри цикла, для каждого месяца строится диаграмма рассеивания нормализованного потребления регионов ОЭС Урала (рис. 4). Как видно из рис. 4, нормализованное электропотребление зимой статистически значимо выше, чем нормализованное электропотребление летом по всей ОЭС Урала. Более того, внутри цикла сезонности с января по декабрь электропотребление меняется по квадратичной функции U-образного вида с минимумом в июне. Данные особенности можно моделировать, как упоминалось ранее, через добавление фиктивных переменных на каждый месяц цикла, либо с помощью полиномов Фурье.

Выявленная структура сезонности внутри года преимущественно объясняется температурой окружающей среды в регионе. Для того чтобы включить в модель соответствующую переменную, была рассчитана среднемесячная температура для столицы каждого региона (в градусах Цельсия) для всего периода наблюдений. Данные были собраны с метеорологического портала ООО «Расписание погоды» (<https://rp5.ru/>).




Рис. 4. Диаграмма размаха нормализованного потребления электроэнергии регионов ОЭС Урала по месяцам

4. Методология исследования

Для построения прогноза электропотребления исходная выборка регионов ОЭС Урала была разбита на 3 части: обучающая, тестовая № 1 и тестовая № 2. В обучающую выборку вошли все наблюдения с января 2008 по сентябрь 2017 г., в тестовую выборку № 1 — с октября 2017 по сентябрь 2018 г., в тестовую выборку № 2 — с октября 2018 по сентябрь 2019 г.

На первом шаге на обучающей выборке строится бенчмарк-модель без учета сезонности, которая необходима для сравнения ее предсказательной силы с представленными далее моделями, учитывающими сезонность. В качестве бенчмарка была выбрана модель $ARIMA(p,d,q)$ электропотребления со следующей спецификацией:

$$\Delta^d C_t = \mu + \sum_{i=1}^p \alpha_i \Delta^d C_{t-i} + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + \eta \cdot Temp_t + \varepsilon_t, \quad (2)$$

где C_t — потребление электроэнергии в месяц t ; $Temp_t$ — среднемесячная температура в месяц t ; p и q — число авторегрессионных лагов самого ряда и остатков соответственно; d — порядок интегрированности ряда. Оптимальное число лагов и порядок интегрированности определяются с помощью пошагового алгоритма выбора оптимальной спецификации, предложенного Hyndman, Khandakar (2008).

На втором шаге на обучающей выборке строятся базовые модели потребления электроэнергии: модель $ARIMA$ с учетом детерминированной сезонности через полиномы Фурье, сезонная авторегрессионная модель $SARIMA$ и периодическая авторегрессионная модель PAR .

Модель $ARIMA(p,d,q)$ электропотребления с учетом сезонности с помощью полиномов Фурье (Soares, Medeiros, 2008) имеет следующую спецификацию:

$$\Delta^d C_t = \mu + \sum_{i=1}^p \alpha_i \Delta^d C_{t-i} + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + \sum_{k=0}^{K/2} \left(A_k \sin\left(\frac{2\pi k}{K} t\right) + B_k \cos\left(\frac{2\pi k}{K} t\right) \right) + \eta \cdot Temp_t + \varepsilon_t, \quad (3)$$

где p , q , d — это порядок авторегрессии самого ряда, его остатков и порядок интегрированности ряда, соответственно, которые определяются также как и в (2) по пошаговому алгоритму Hyndman, Khandakar (2008); K — длина цикла сезонности ряда, в данной работе по итогам анализа периодограммы было выявлено, что эта длина равна 12 месяцам.

Сезонная модель $SARIMA(p,d,q)(P,D,Q)_K$ электропотребления (Pappas et al., 2008; Abosedra et al., 2009; Abledu, 2013) имеет следующую спецификацию:

$$\Delta^d C_t = \mu + \sum_{i=1}^p \alpha_i \Delta^d C_{t-i} + \sum_{l=1}^P \gamma_l \Delta C_{t-K \cdot l} + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + \sum_{s=1}^Q \delta_s \varepsilon_{t-K \cdot s} + \eta \cdot Temp_t + \varepsilon_t, \quad (4)$$

где p , q , d — порядок авторегрессии самого ряда, его остатков и интегрированности ряда соответственно; P и Q — число сезонных лагов самого ряда и его остатков соответственно; D — порядок сезонного интегрирования. Параметры p , q , d , P , D и Q выбираются в соответствии с пошаговым алгоритмом Hyndman, Khandakar (2008).

Периодическая авторегрессионная модель первого порядка PAR(1) имеет следующую спецификацию (Espinoza et al., 2005; Maceira, Damázio, 2006):

$$C_t = \mu_0 t + \sum_{s=1}^K \mu_s D_{s,t} + \sum_{s=1}^K \alpha_s C_{t-1} D_{s,t} + \eta \cdot Temp_t + \varepsilon_t, \quad (5)$$

где t — линейный тренд; $D_{s,t}$ — индикаторная функция на отдельный сезон (месяц) s внутри года ($s = 1, \dots, 12$); μ_s — константа, уникальная для сезона s ; α_s — авторегрессионный коэффициент, уникальный для сезона s . Число лагов в данной модели выбрано равным 1, как максимальное число лагов, при котором модель на обучающей выборке может быть идентифицируема.

На третьем шаге по построенным моделям (3), (4), (5) строятся соответственные прогнозы F_t^{ARIMA} , F_t^{SARIMA} , F_t^{PAR} на тестовую выборку № 1. После этого строится линейная комбинация прогнозов. Такая техника носит название «combination forecast» в эконометрике и статистике (Wang et al., 2012; Xiao et al., 2016) и «bagging» как частный случай ансамблевых методов в машинном обучении (Chou, Tran, 2018).

Линейная комбинация в данной работе строится двумя способами. При первом способе (Wang et al., 2012; Nowotarski et al., 2016) веса для линейной комбинации выбираются в соответствии с коэффициентами следующей регрессии (regression based combination):

$$C_t = w_0 + w_1 F_t^{ARIMA} + w_2 F_t^{SARIMA} + w_3 F_t^{PAR} + \varepsilon_t. \quad (6)$$

Назовем такой подход линейной комбинацией прогнозов с весами из регрессии (ЛКПР).

При втором способе (Nowotarski et al., 2016) веса выбираются обратно пропорционально ошибке прогноза моделей (performance based combination) на тестовой выборке № 1. А именно, на тестовой выборке № 1 для каждой базовой модели i рассчитывается средняя абсолютная ошибка прогноза в процентах (MAPE), и веса для линейной комбинации выбираются следующим образом:

$$w_i = \frac{1 - MAPE_i}{\sum_{i \in I} (1 - MAPE_i)}, \quad i \in I = \{ARIMA, SARIMA, PAR\}. \quad (7)$$

Назовем такой подход линейной комбинацией прогноза с весами, пропорциональными ошибке (ЛКПО).

На четвертом шаге строится прогноз потребления с помощью линейных комбинаций (ЛКПР и ЛКПО) на тестовую выборку № 2, а именно строится прогноз с периодом 1 месяц для горизонта прогнозирования 1 год. Затем для указанного горизонта оценивается качество прогноза. Для измерения предсказательной силы различных регрессионных моделей используются стандартные показатели прогнозного качества: средняя квадратичная ошибка прогноза (Root Mean Squared Error, RMSE) и средняя абсолютная ошибка прогноза в процентах (Mean Absolute Percentage Error, MAPE). Отметим, что и RMSE, и MAPE являются рекомендуемыми показателями оценки качества прогноза системным оператором ЕЭС РФ

в соответствии с методикой прогнозирования графиков электропотребления⁹. Однако на практике чаще применяется показатель MAPE, см., например, Регламент оперативного диспетчерского управления электроэнергетическим режимом объектов управления ЕЭС России (принятый в 2006 г.) или (Nowotarski et al., 2016). Это обусловлено тем, что в данном случае ошибка прогноза является относительной и выражается в процентах, что, во-первых, делает ее интерпретируемой, а во-вторых, позволяет сравнивать качество прогноза в разных исследованиях.

Для проверки устойчивости результатов прогнозирования строится прогноз F_t с помощью линейных комбинаций ЛКПО и ЛКПР с периодом 1 месяц для горизонта прогнозирования h от 1 месяца до 1 года, $h = 1, \dots, 12$. Оценка качества прогноза для горизонта прогнозирования h рассчитывается следующим образом:

$$MAPE_h = \frac{1}{h} \sum_{t=1}^h |C_t - F_t| / C_t. \quad (8)$$

5. Эмпирические результаты

В соответствии с описанным выше алгоритмом, на первом шаге оценивалась модель ARIMA без сезонности, затем на втором шаге для каждого региона на обучающей выборке были оценены базовые модели: ARIMA с полиномами Фурье, сезонная авторегрессионная модель SARIMA и периодическая авторегрессионная модель PAR. Выбранный порядок авторегрессии ряда, остатков и порядок интегрированности моделей ARIMA без сезонности и с сезонностью отдельно для каждого региона представлены в Приложении. Как видно из табл. 1, скорректированные коэффициенты детерминации для каждой из трех моделей близки к единице, что говорит о высоком качестве подгонки данных моделями. При этом коэффициент детерминации в базовых моделях значительно выше (на 7–11%), чем в простейшей модели ARIMA без сезонности, что показывает необходимость учета сезонности

Таблица 1. Коэффициент детерминации моделей на обучающей выборке (январь 2008 — сентябрь 2017 г.)

	Без сезонности	PAR	SARIMA	ARIMA с полиномами Фурье
Челябинская область	0.870	0.962	0.958	0.962
Свердловская область	0.884	0.959	0.942	0.956
Пермский край	0.883	0.977	0.976	0.977
Республика Башкортостан	0.905	0.982	0.981	0.983
Оренбургская область	0.901	0.971	0.911	0.962
Курганская область	0.901	0.979	0.966	0.976
Кировская область	0.900	0.976	0.970	0.978
Тюменская область	0.875	0.986	0.981	0.981
Удмуртская республика	0.898	0.983	0.981	0.986

⁹ См. https://so-ups.ru/fileadmin/files/laws/market_regulations/schedules.pdf.

при прогнозировании спроса на электроэнергию. Если сравнивать по этому коэффициенту базовые модели, то лучший результат на обучающей выборке в большинстве регионов дает периодическая авторегрессионная модель (PAR). Исключения составляют республика Башкортостан, Кировская область и Удмуртская республика, где коэффициенты детерминации при использовании авторегрессионной модели PAR и ARIMA с полиномами Фурье близки, но для последней модели несколько выше.

Показатели прогнозного качества моделей без учета сезонности и с учетом сезонности (PAR, SARIMA, ARIMA с полиномами Фурье) и линейных комбинаций (ЛКПР и ЛКПО) с периодом прогнозирования 1 месяц и горизонтом прогнозирования 1 год представлены в табл. 2 и 3 соответственно. По обоим показателям качества прогноза модель без сезонности демонстрирует значительно меньшую прогнозную силу, чем остальные модели для всех регионов. Сравнительный анализ качества прогнозов базовых моделей показывает, что по RMSE наилучший результат в большинстве регионов дает модель ARIMA с полиномами Фурье. Исключением являются республика Башкортостан и Кировская области, где лучший прогноз дает модель SARIMA. В Курганской области качество прогноза при использовании двух упомянутых моделей почти одинаково.

Таблица 2. Прогнозная сила моделей электропотребления для регионов ОЭС Урала по RMSE на 1 год вперед (октябрь 2018 — сентябрь 2019 г.)

	Без сезонности	PAR	SARIMA	ARIMA с полиномами Фурье	ЛКПР	ЛКПО
Челябинская область	291.819	50.109	50.022	49.092	50.824	45.095
Свердловская область	416.646	57.976	55.428	51.636	126.721	49.100
Пермский край	245.424	29.612	22.874	22.435	31.543	18.861
Республика Башкортостан	303.034	51.719	39.554	61.862	69.837	38.321
Оренбургская область	30.366	14.570	22.349	10.082	7.989	14.226
Курганская область	73.935	9.077	6.699	6.793	7.327	5.733
Кировская область	83.373	29.018	14.582	21.411	10.990	21.096
Тюменская область	740.403	493.929	400.827	297.489	176.017	394.611
Удмуртская республика	100.509	39.237	19.154	14.402	9.270	23.207

Использование линейных комбинаций (ЛКПР и ЛКПО) по показателю RMSE улучшает качество прогноза для всех регионов. Лучший прогноз для Челябинской, Свердловской и Курганской областей, Пермского края и республики Башкортостан дает использование линейной комбинации с весами, обратно пропорциональными ошибке прогноза (ЛКПО). В то время как для Оренбургской, Кировской и Тюменской (с прилегающими территориями) областей и Удмуртской республики лучшим является прогноз, полученный с весами из регрессии (ЛКПР). Из таблицы 2 видно, что наиболее существенное улучшение качества прогноза при использовании линейных комбинаций, как ЛКПР, так и ЛКПО, в сравнении с базовыми моделями происходит для Тюменской и Оренбургской областей и Удмуртской республики. В то время как для республики Башкортостан и Свердловской области улучшения качества прогноза незначительное.

Аналогичные результаты наблюдаются при использовании средней абсолютной ошибки прогноза в процентах (MAPE) для оценки качества прогноза (табл. 3). Для большинства регионов прогнозное качество модели ARIMA с полиномами Фурье выше, чем у двух других базовых моделей. Однако в республике Башкортостан и Кировской области наилучшим среди базовых моделей прогнозом характеризуется модель SARIMA. Результаты примечательны тем, что в разных регионах лучший прогноз дают либо модели с детерминированной сезонностью, либо со стохастической. Также хочется отметить, что, хотя модель PAR обладает наибольшей объясняющей силой на обучающей выборке (см. табл. 1), на прогнозной выборке №2 PAR ни для одного региона не дает лучший прогноз (в сравнении с остальными базовыми моделями) ни по показателю RMSE, ни по показателю MAPE.

Таблица 3. Прогнозная сила моделей электропотребления для регионов ОЭС Урала по MAPE на 1 год вперед (октябрь 2018 — сентябрь 2019 г.)

	Без сезонности	PAR	SARIMA	ARIMA с полиномами Фурье	ЛКПР	ЛКПО
Челябинская область	8.896	1.474	1.338	1.352	1.363	1.180
Свердловская область	10.181	1.452	1.295	1.188	3.161	1.256
Пермский край	10.918	1.165	0.849	0.850	1.344	0.780
Республика Башкортостан	11.600	1.811	1.577	2.198	2.766	1.538
Оренбургская область	14.110	7.262	10.961	4.552	3.534	7.105
Курганская область	18.073	2.370	1.573	1.391	1.703	1.218
Кировская область	12.042	4.319	1.996	2.941	1.598	3.047
Тюменская область	8.008	6.203	5.079	3.696	1.871	4.983
Удмуртская республика	11.017	4.783	2.166	1.455	0.962	2.773

В таблице 3 для всех регионов линейные комбинации прогнозов демонстрируют улучшение качества прогноза в сравнении с отдельными базовыми моделями: для Тюменской области с прилегающими территориями показатель MAPE уменьшается с 3.70 до 1.87%, для Оренбургской области — с 4.6 до 3.5%, для Удмуртской республики — с 1.46 до 0.96%. Более того, Пермский край и Удмуртская республика характеризуются достаточно высоким качеством прогноза по сравнению с другими регионами, в обоих регионах MAPE меньше 1%.

В целом, при прогнозировании на 1 год вперед лучшим прогнозным качеством как по показателю MAPE, так и по RMSE обладает ЛКПО в Пермском крае, Челябинской области, республике Башкортостан и Курганской области и ЛКПР — в Оренбургской, Кировской и Тюменской областях и Удмуртской республике. Это можно объяснить следующим образом. В ЛКПО веса всегда положительные, тогда как в ЛКПР это не так. Как видно из таблиц 2 и 3, для Кировской области модель PAR обладает более слабой предсказательной силой, чем другие базовые модели. Таким образом, при конструировании линейной комбинации ЛКПО прогнозу по данной модели (PAR) все равно присваивается небольшой, но положительный, вес, что понижает качество прогноза ЛКПО в сравнении с ЛКПР, где прогнозу по PAR присваивается отрицательный вес. То есть во всех регионах, где лучшей моделью является ЛКПР, прогноз по модели PAR значительно хуже, чем по другим базовым

моделям. А во всех регионах, где лучшей моделью является ЛКПО, прогнозы по всем трем базовым моделям сопоставимы, и значительных различий по качеству прогнозной силы нет. Исключительным регионом является Свердловская область, в ней прогнозы по трем базовым моделям не являются сопоставимыми, однако и прогноз по модели PAR не сильно уступает другим моделям. Это приводит к тому, что в данном регионе по показателю RMSE лучшим качеством обладает ЛКПО, по MAPE — модель ARIMA с полиномами Фурье.

Динамика MAPE для разных горизонтов прогнозирования (от 1 месяца до 1 года) в разрезе регионов ОЭС представлена на рис. 5 и 6 для ЛКПО и ЛКПР соответственно. Большинство регионов обладает устойчивостью результатов прогнозирования к увеличению горизонта. Во-первых, при увеличении горизонта от 1 месяца до 1 года происходит повышение показателя ошибки прогноза MAPE, однако это рост достаточно небольшой (не больше 1.5 п.п.). Исключением является Оренбургская область, ошибки прогноза для которой как для ЛКПО, так и для ЛКПР с увеличением горизонта увеличиваются в 2 раза, при этом они значительно больше ошибок по другим регионам. Возможной причиной этого может являться шок в энергосистеме, который произошел в исследуемый временной период¹⁰. Во-вторых, выбор лучшей модели почти по всем регионам, за исключением Курганской области, устойчив к изменению горизонта прогнозирования.

Хочется отметить, что полученные ошибки прогноза (см. табл. 3) по всем регионам удовлетворяют требованиям Регламента оперативного диспетчерского управления электроэнергетическим режимом объектов управления ЕЭС России (2006). В рамках регламента средняя величина ошибки прогноза потребления, рассчитанная за период не менее месяца, не должна превышать: по единой энергетической системе (ЕЭС) России — 1.5%, по объединенной энергетической системе (ОЭС) — 2.5%, по региональной электроэнергетической системе (РЭЭС) — 5%. В регламенте зафиксирован уровень ошибки прогноза для высокочастотных данных. Очевидно, что имея менее частотные данные, такие величины средних ошибок прогноза по регламенту могут рассматриваться в качестве верхней границы. Хочется отметить, что при диспетчеризации значения ошибок чаще всего значительно меньше (Макоклюев и др., 2019). При этом для отдельных ОЭС нет единых жестко зафиксированных нормативов ошибки прогноза. Макоклюев и др. (2019) отмечают, что нормативы утверждаются каждые полгода отдельно для каждого диспетчерского центра, однако они не являются открытыми, поэтому нет возможности сравнить с ними результаты, полученные в данной работе.

Аналогичных исследований по среднесрочному прогнозированию электропотребления на данных российских регионов, насколько известно авторам, нет. Однако можно выделить несколько российских исследований последних лет, где строится прогноз для разных периодов. Соловьева и Дзюба (2013) сформулировали рекомендации отдельным субъектам оптового рынка по построению прогноза со средней ошибкой (MAPE) не больше 5–6% в сутки. Доманов и Билалова (2014) на данных одного субъекта оптового рынка (МУП «Ульяновская городская электросеть») демонстрируют ошибку порядка 5–10%. Бурковский и др. (2015) на данных Воронежской области показывают качество прогноза на каждый день 0.09–2.22%. Таким образом, показатели ошибки прогноза в настоящей работе не хуже, чем в других российских исследованиях.

¹⁰ Вероятно, в Оренбургской области такой шок произошел в 2016 г. после строительства ряда объектов сетевой инфраструктуры энергосистемы, что привело к уменьшению дефицита электроэнергии в центральном энергорайоне Оренбургской области (Батарин и др., 2018).




Рис. 5. Средний абсолютный процент ошибки (MAPE) для разных горизонтов прогнозирования по линейной комбинации прогнозов с весами из регрессии (ЛКПР)




Рис. 6. Средний абсолютный процент ошибки (MAPE) для разных горизонтов прогнозирования по линейной комбинации прогнозов с весами, обратно пропорциональными ошибке (ЛКПО)

6. Заключение

Потребление электроэнергии различных регионов и стран характеризуется разными сезонными колебаниями, что необходимо учитывать при прогнозировании. В данной работе с использованием унифицированного алгоритма, включающего построение регрессионных моделей, учитывающих разные типы сезонности (детерминированную и стохастическую) и температуру окружающей среды, построен прогноз электропотребления 9 регионов ОЭС Урала на 1 год вперед с периодом в 1 месяц. Для этого используются месячные данные об электропотреблении в период с 2008 по 2019 г.

Предварительный анализ данных указывает на ярко выраженную сезонность потребления электроэнергии регионов внутри года, однако он не позволяет определить ее тип. Поэтому для целей прогнозирования применяются модели, учитывающие как детерминированную, так и стохастическую сезонности. Для каждого региона построены 3 базовые

регрессионные модели электропотребления: модель ARIMA с полиномами Фурье (для учета детерминированной сезонности), модель SARIMA и модель PAR (для учета стохастической сезонности), а также бенчмарк-модель без учета сезонности. Далее для каждого региона рассчитаны два варианта линейных комбинаций прогнозов — с весами, определенными из регрессионного уравнения, и с весами, пропорциональными ошибке MAPE. Для оценки качества прогноза по базовым моделям, а также сконструированных на их основе линейных комбинаций были использованы показатели RMSE и MAPE. Кроме того, проведена проверка устойчивости результатов к горизонту прогнозирования по показателю MAPE.

Проведенное исследование показало, что модели электропотребления с учетом сезонных колебаний демонстрируют более высокое качество прогноза, чем модели, не учитывающие их. Для каждого из регионов более высокая прогнозная сила характерна для моделей с разным типом сезонных колебаний. Для Челябинской, Свердловской, Курганской, Оренбургской и Тюменской областей, Пермского края и Удмуртской республики более высокое качество прогноза демонстрируют модели, учитывающие детерминированную сезонность, а для Кировской области и республики Башкортостан — модели с учетом стохастической сезонности. Вместе с тем, наилучшее качество прогноза для всех регионов демонстрирует линейная комбинация прогнозов. Данный результат по большей части совпадает для показателей качества прогноза RMSE и MAPE. Повышение качества прогноза по линейным комбинациям в сравнении с лучшей из базовых моделей для каждого региона оказалось значительным: MAPE сократилась от 0.04 п.п. до 1.83 п.п. по разным регионам.

Улучшение качества прогноза линейных комбинаций по сравнению с базовыми моделями является устойчивым с точки зрения изменения горизонта прогнозирования от 1 месяца до 1 года. Отметим, что в разных регионах лучшими (с точки зрения прогнозной силы) являются различные спецификации линейных комбинаций. Для Челябинской, Свердловской и Курганской областей, Пермского края и республики Башкортостан наилучшей оказалась линейная комбинация с весами, обратно пропорциональными ошибке (ЛКПО), тогда как в остальных регионах ОЭС — линейная комбинация с весами по регрессии (ЛКПР). Причиной этого является значительная ошибка прогноза модели PAR для Оренбургской, Кировской и Тюменской областей и Удмуртской республики и ее положительный вес в линейной комбинации ЛКПО, хотя для данных областей более соответствующим является отрицательный вес, что отражено в ЛКПР.

Апробированный в работе алгоритм построения среднесрочного прогноза электропотребления может быть использован как отдельными участниками рынка электроэнергетики, так и региональными диспетчерскими управлениями. Более того, он может быть распространен на другие регионы и ОЭС России.

Список литературы

- Антонов Н., Лукина Е. (2013). Методические подходы к прогнозированию электропотребления. *Энергорынок*, 9 (114), 32–39.
- Батарин Д., Берсенин А., Рябовол Е., Толкачева Ю., Беляев Ю., Хяккинен А., Сермавбрин А., Парфенова М., Кошкина Л., Стрелкова Е., Усенко Е., Зенина О. (2018). Портрет региона. Оренбургское РДУ. *50 Герц*, 2–3 (30–31), 22–32.

Бессонов В. А., Петровев А. В. (2013). Сезонная корректировка как источник ложных сигналов. *Экономический журнал Высшей школы экономики*, 17 (4), 554–584.

Бурковский В. Л., Крысанов В. Н., Руцков А. Л., Шукур О. Ш. М. (2015). Модель прогнозирования регионального энергопотребления на базе нечеткой нейронной сети. *Вестник Воронежского государственного технического университета*, 11 (5), 41–46.

Гордиенко А. С., Лозинская А. М., Тетерина Д. В., Шенкман Е. А. (2019). Исследование зависимости потребления электроэнергии и температуры в России: региональный разрез. *Известия Российской академии наук. Энергетика*, 1, 15–27.

Дзагуто В., Дятел Т., Крючкова Е. (2018). Счетчики подключают к потолку: Белый дом опять начал реформу энерготарифов для населения. *Газета «Коммерсантъ»* № 179 от 02.10.2018. <https://www.kommersant.ru/doc/3758393>.

Доманов В. И., Билалова А. И. (2014). Анализ прогнозирования энергопотребления с различными информационными базами. *Известия Самарского научного центра Российской академии наук*, 16 (4), 535–537.

Макоклюев Б. И. (2008). *Анализ и планирование электропотребления*. М.: Энергоатомиздат.

Макоклюев Б. И., Полижаров А. С., Антонов А. В., Говорун М. Н., Колесников А. В., Басов А. А., Алла Ю. Э. (2019). Оперативная коррекция графиков потребления электрической мощности в цикле планирования балансирующего рынка. *Электрические станции*, 5, 36–44.

Ожегов Е. М., Попова Е. А. (2017). Спрос на электроэнергию и погода в регионе: непараметрический подход. *Прикладная эконометрика*, 2 (46), 55–73.

Пилениекс Д. В. (2018). Планирование развития ЕЭС России и долгосрочное планирование электроэнергетического режима ЕЭС России. http://so-ups.ru/fileadmin/files/company/events/2018/konf_3_110918_prez_02_develop.pdf.

Пильник Н. П., Поспелов И. Г., Станкевич И. П. (2015). Об использовании фиктивных переменных для решения проблемы сезонности в моделях общего экономического равновесия. *Экономический журнал Высшей школы экономики*, 19 (2), 249–270.

Соловьева И. А., Дзюба А. П. (2013). Прогнозирование электропотребления с учетом факторов технологической и рыночной среды. *Научный диалог*, 7 (19), 97–113.

Abosedra S., Dah A., Ghosh S. (2009). Demand for electricity in Lebanon. *International Business & Economics Research Journal (IBER)*, 8 (1), 11–18.

Abledu G. K. (2013). Modeling and forecasting energy consumption in Ghana. *Journal of Energy Technologies and Policy*, 3 (12), 1–10.

Box G. E., Jenkins G. M., Reinsel G. C. (2008). *Time series analysis*. Oxford: Wiley.

Broszkiewicz-Suwaj E., Makagon A., Weron R., Wylomańska A. (2004). On detecting and modeling periodic correlation in financial data. *Physica A: Statistical Mechanics and its Applications*, 336 (1–2), 196–205.

Cao G., Wu L. (2016). Support vector regression with fruit fly optimization algorithm for seasonal electricity consumption forecasting. *Energy*, 115, 734–745.

Chen K. Y., Wang C. H. (2007). A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan. *Expert Systems with Applications*, 32 (1), 254–264.

Cho H., Goude Y., Brossat X., Yao Q. (2013). Modeling and forecasting daily electricity load curves: A hybrid approach. *Journal of the American Statistical Association*, 108 (501), 7–21.

- Cho S., Kim T., Kim H. J., Park K., Roberts R. K. (2015). Regionally-varying and regionally-uniform electricity pricing policies compared across four usage categories. *Energy Economics*, 49, 182–191.
- Chou J. S., Tran D. S. (2018). Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders. *Energy*, 165, 709–726.
- Clements A. E., Hurn A. S., Li Z. (2016). Forecasting day-ahead electricity load using a multiple equation time series approach. *European Journal of Operational Research*, 251 (2), 522–530.
- Espinoza M., De Moor B., Joye C., Belmans R. (2005). Local load analysis with periodic time series and temperature adjustment. *Proceedings of the 15th Power Systems Computation Conference (PSCC)*, Liege, 22–26 August, 2005, 1–7.
- Guo H., Chen Q., Xia Q., Kang C., Zhang X. (2018). A monthly electricity consumption forecasting method based on vector error correction model and self-adaptive screening method. *International Journal of Electrical Power & Energy Systems*, 95, 427–439.
- Harvey A. (2006). Forecasting with unobserved components time series models. In: *Handbook of economic forecasting*, 1, 327–412.
- Hunt L. C., Judge G., Ninomiya Y. (2003). Underlying trends and seasonality in UK energy demand: A sectoral analysis. *Energy Economics*, 25 (1), 93–118.
- Hyndman R. J., Khandakar Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27 (3), 1–22.
- Maceira M. E. P., Damázio J. M. (2006). Use of the PAR(p) model in the stochastic dual dynamic programming optimization scheme used in the operation planning of the Brazilian hydropower system. *Probability in the Engineering and Informational Sciences*, 20 (1), 143–156.
- Nowotarski J., Liu B., Weron R., Hong T. (2016). Improving short term load forecast accuracy via combining sister forecasts. *Energy*, 98, 40–49.
- Pappas S., Ekonomou L., Karamousantas D., Chatzarakis G., Katsikas S., Liatsis P. (2008). Electricity demand loads modeling using AutoRegressive Moving Average (ARMA) models. *Energy*, 33 (9), 1353–1360.
- Shiskin J. (1978). Seasonal adjustment of sensitive indicators. In: *Seasonal Analysis of Economic Time Series*, 97–103. NBER. <https://www.nber.org/system/files/chapters/c4323/c4323.pdf>.
- Shiskin J., Young A. H., Musgrave J. C. (1967). *The X-11 variant of the Census method II seasonal adjustment program*. U.S. Government Printing Office: Washington D.C.
- Soares L. J., Medeiros M. C. (2008). Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data. *International Journal of Forecasting*, 24 (4), 630–644.
- Taylor J. W., McSharry P. E. (2007). Short-term load forecasting methods: An evaluation based on European data. *IEEE Transactions on Power Systems*, 22 (4), 2213–2219.
- Wang Y., Wang J., Zhao G., Dong Y. (2012). Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: A case study of China. *Energy Policy*, 48, 284–294.
- Xiao L., Shao W., Liang T., Wang C. (2016). A combined model based on multiple seasonal patterns and modified firefly algorithm for electrical load forecasting. *Applied Energy*, 167, 135–153.
- Zhang X., Wang J., Zhang K. (2017). Short-term electric load forecasting based on singular spectrum analysis and support vector machine optimized by Cuckoo search algorithm. *Electric Power Systems Research*, 146, 270–285.

Поступила в редакцию 05.06.2020;
принята в печать 20.09.2020.

Приложение

Таблица П1. Оптимальные спецификации моделей (2), (3), (4) в соответствии с пошаговым алгоритмом (Hyndman, Khandakar, 2008)

Регион	Без сезонности	ARIMA с полиномами Фурье	SARIMA
Челябинская область	ARIMA(2,0,2)	ARIMA(1,0,2)	SARIMA(1,0,0)(2,1,1) ₁₂
Свердловская область	ARIMA(2,1,1)	ARIMA(0,1,0)	SARIMA(1,0,0)(2,1,0) ₁₂
Пермский край	ARIMA(0,1,1)	ARIMA(0,1,1)	SARIMA(0,1,1)(1,1,1) ₁₂
Республика Башкортостан	ARIMA(2,1,3)	ARIMA(0,1,2)	SARIMA(0,1,2)(0,1,1) ₁₂
Оренбургская область	ARIMA(1,1,3)	ARIMA(1,1,1)	SARIMA(0,1,0)(0,0,2) ₁₂
Курганская область	ARIMA(1,0,0)	ARIMA(1,0,0)	SARIMA(1,0,0)(2,1,0) ₁₂
Кировская область	ARIMA(1,0,1)	ARIMA(0,1,1)	SARIMA(1,0,1)(2,1,0) ₁₂
Тюменская область	ARIMA(1,1,1)	ARIMA(0,1,1)	SARIMA(1,0,1)(2,1,1) ₁₂
Удмуртская республика	ARIMA(1,1,2)	ARIMA(0,1,2)	SARIMA(1,0,2)(2,1,0) ₁₂

Lozinskaia A., Redkina A., Shenkman E. Electricity consumption forecasting for integrated power system with seasonal patterns. *Applied Econometrics*, 2020, v. 60, pp. 5–25.

DOI: 10.22394/1993-7601-2020-60-5-25

Agata Lozinskaia

National Research University Higher School of Economics, Perm, Russian Federation;
alozinskaia@hse.ru

Anastasiia Redkina

National Research University Higher School of Economics, Perm, Russian Federation;
aredkina@hse.ru

Evgeniia Shenkman

National Research University Higher School of Economics, Perm, Russian Federation;
ea_popova@hse.ru

Electricity consumption forecasting for integrated power system with seasonal patterns

In the paper, a medium-term forecast of electricity consumption is built on monthly data from January 2008 to September 2019 for all regions of the Urals integrated power system. A key feature of the work is the use of linear combinations of forecasts that are produced with time series basic models with deterministic and stochastic seasonality. The proposed methodology demonstrates high and robust forecast accuracy in comparison with the basic models and can be applied by various players in the electricity market.

Keywords: wholesale electricity market; electricity consumption forecasting; deterministic seasonality; stochastic seasonality.

JEL classification: C53; Q47.

References

- Antonov N., Lukina E. (2013). Metodicheskie podkhody k prognozirovaniyu elektropotrebleniya. *Energorynok*, 9 (114), 32–39 (in Russian).
- Batarin D., Bersenin A., Ryabovol E., Tolkacheva Yu., Belyaev Yu., Hyakkinen A., Sermavbrin A., Parfenova M., Koshkina L., Strelkova E., Usenko E., Zenina O. (2018). Portret regiona. Orenburgskoe RDU. *50 Gerc*, 2–3 (30–31), 22–32 (in Russian).
- Bessonov V., Petronevich A. (2013). Seasonal adjustment as a source of spurious signals. *HSE Economic Journal*, 17 (4), 586–616 (in Russian).
- Burkovsky V. L., Krysanov V. N., Rutkov A. L., Shukur O. Sh. M. (2015). Model of forecasting of regional energy consumption on the basis of the indistinct neural network. *The Bulletin of Voronezh State Technical University*, 11 (5), 41–46 (in Russian).
- Gordienko A. S., Lozinskaia, A. M., Teterina D. V., Shenkman E. A. (2019). Research on relationship between electricity consumption and air temperature in Russia: Regional view. *Izvestiia Rossiiskoi akademii nauk. Energetika*, 1, 15–27 (in Russian).
- Dzaguto V., Dyatel T., Kryuchkova E. (2018). Schetchiki podklyuchayut k potolku: Belyj dom opyat' nachal reformu energotarifov dlya naseleniya. *Gazeta Kommersant*, № 179 ot 02.10.2018. <https://www.kommersant.ru/doc/3758393> (in Russian).
- Domanov V. I., Bilalova A. I. (2014). Analysis of forecasting the energy consumption with various data bases. *Izvestia of Samara Scientific Center of the Russian Academy of Sciences*, 16 (4), 535–537 (in Russian).
- Makoklyuev B. I. (2008). *Analiz i planirovanie elektropotrebleniya*. M.: Energoatomizdat (in Russian).
- Makoklyuev B. I., Polizharov A. S., Antonov A. V., Govorun M. N., Kolesnikov A. V., Basov A. A., Alla Yu. E. (2019). Operativnaya korrekciya grafikov potrebleniya elektricheskoy moshchnosti v cikle planirovaniya balansiruyushchego rynka. *Elektricheskie stancii*, 5, 36–44 (in Russian).
- Ozhegov E., Popova E. (2017). Demand for electricity and weather conditions: Nonparametric analysis, *Applied Econometrics*, 46 (2), 55–73 (in Russian).
- Pilenieks D. V. (2018). Planirovanie razvitiya EES Rossii i dolgosrochnoe planirovanie elektroenergeticheskogo rezhima EES Rossii. http://so-ups.ru/fileadmin/files/company/events/2018/konf_3_110918_prez_02_develop.pdf (in Russian).
- Pilnik N., Pospelov I., Stankevich I. (2015) On the use of dummy variables to solve the problem of seasonality in general equilibrium models. *HSE Economic Journal*, 19 (2), 249–270 (in Russian).
- Solovjeva I. A., Dzyuba A. P. (2013). Forecasting electric energy consumption with factors of process and market environment taken into account. *Nauchnyi dialog*, 7 (19), 97–113 (in Russian).
- Abosedra S., Dah A., Ghosh S. (2009). Demand for electricity in Lebanon. *International Business & Economics Research Journal (IBER)*, 8 (1), 11–18.
- Abledu G. K. (2013). Modeling and forecasting energy consumption in Ghana. *Journal of Energy Technologies and Policy*, 3 (12), 1–10.
- Box G. E., Jenkins G. M., Reinsel G. C. (2008). *Time series analysis*. Oxford: Wiley.
- Broszkiewicz-Suwaj E., Makagon A., Weron R., Wyłomańska A. (2004). On detecting and modeling periodic correlation in financial data. *Physica A: Statistical Mechanics and its Applications*, 336 (1–2), 196–205.
- Cao G., Wu L. (2016). Support vector regression with fruit fly optimization algorithm for seasonal electricity consumption forecasting. *Energy*, 115, 734–745.
- Chen K. Y., Wang C. H. (2007). A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan. *Expert Systems with Applications*, 32 (1), 254–264.

Cho H., Goude Y., Brossat X., Yao Q. (2013). Modeling and forecasting daily electricity load curves: A hybrid approach. *Journal of the American Statistical Association*, 108 (501), 7–21.

Cho S., Kim T., Kim H. J., Park K., Roberts R. K. (2015). Regionally-varying and regionally-uniform electricity pricing policies compared across four usage categories. *Energy Economics*, 49, 182–191.

Chou J. S., Tran D. S. (2018). Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders. *Energy*, 165, 709–726.

Clements A. E., Hurn A. S., Li Z. (2016). Forecasting day-ahead electricity load using a multiple equation time series approach. *European Journal of Operational Research*, 251 (2), 522–530.

Espinoza M., De Moor B., Joye C., Belmans R. (2005). Local load analysis with periodic time series and temperature adjustment. *Proceedings of the 15th Power Systems Computation Conference (PSCC)*, Liege, 22–26 August, 2005, 1–7.

Guo H., Chen Q., Xia Q., Kang C., Zhang X. (2018). A monthly electricity consumption forecasting method based on vector error correction model and self-adaptive screening method. *International Journal of Electrical Power & Energy Systems*, 95, 427–439.

Harvey A. (2006). Forecasting with unobserved components time series models. In: *Handbook of economic forecasting*, 1, 327–412.

Hunt L. C., Judge G., Ninomiya Y. (2003). Underlying trends and seasonality in UK energy demand: A sectoral analysis. *Energy Economics*, 25 (1), 93–118.

Hyndman R. J., Khandakar Y. (2008). Automatic time series forecasting: The forecast package for R. *Journal of Statistical Software*, 27 (3), 1–22.

Maceira M. E. P., Damázio J. M. (2006). Use of the PAR(p) model in the stochastic dual dynamic programming optimization scheme used in the operation planning of the Brazilian hydropower system. *Probability in the Engineering and Informational Sciences*, 20 (1), 143–156.

Nowotarski J., Liu B., Weron R., Hong T. (2016). Improving short term load forecast accuracy via combining sister forecasts. *Energy*, 98, 40–49.

Pappas S., Ekonomou L., Karamousantas D., Chatzarakis G., Katsikas S., Liatsis P. (2008). Electricity demand loads modeling using AutoRegressive Moving Average (ARMA) models. *Energy*, 33 (9), 1353–1360.

Shiskin J. (1978). Seasonal adjustment of sensitive indicators. In: *Seasonal Analysis of Economic Time Series*, 97–103. NBER. <https://www.nber.org/system/files/chapters/c4323/c4323.pdf>.

Shiskin J., Young A. H., Musgrave J. C. (1967). *The X-11 variant of the Census method II seasonal adjustment program*. U.S. Government Printing Office: Washington D.C.

Soares L. J., Medeiros M. C. (2008). Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data. *International Journal of Forecasting*, 24 (4), 630–644.

Taylor J. W., McSharry P. E. (2007). Short-term load forecasting methods: An evaluation based on European data. *IEEE Transactions on Power Systems*, 22 (4), 2213–2219.

Wang Y., Wang J., Zhao G., Dong Y. (2012). Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: A case study of China. *Energy Policy*, 48, 284–294.

Xiao L., Shao W., Liang T., Wang C. (2016). A combined model based on multiple seasonal patterns and modified firefly algorithm for electrical load forecasting. *Applied Energy*, 167, 135–153.

Zhang X., Wang J., Zhang K. (2017). Short-term electric load forecasting based on singular spectrum analysis and support vector machine optimized by Cuckoo search algorithm. *Electric Power Systems Research*, 146, 270–285.

Received 05.06.2020; accepted 20.09.2020.