

УДК: 004.89

Метод построения прогнозной нейросетевой модели временного ряда

Л. Ю. Емалетдинова^a, З. И. Мухаметзянов^b,
Д. В. Катасёва^c, А. Н. Кабирова^d

Казанский национальный исследовательский технический университет им. А. Н. Туполева — КАИ,
Россия, 420111, г. Казань, ул. К. Маркса, д. 10

E-mail: ^a lilia@stcline.ru, ^b banderos25z@gmail.com, ^c 415pisarevad@mail.ru, ^d kabirovaigul@mail.ru

Получено 19.01.2020, после доработки — 18.04.2020.

Принято к публикации 06.05.2020.

В данной статье рассматривается метод построения прогнозной нейросетевой модели временного ряда, основанный на определении состава входных переменных, построения обучающей выборки и самого обучения с использованием метода обратного распространения ошибки. Традиционные методы построения прогнозных моделей временного ряда (авторегрессионной модели, модели скользящего среднего или модели авторегрессии – скользящего среднего) позволяют аппроксимировать временной ряд линейной зависимостью текущего значения выходной переменной от некоторого количества ее предыдущих значений. Такое ограничение, как линейность зависимости, приводит к значительным ошибкам при прогнозировании.

Технологии интеллектуального анализа с применением нейросетевого моделирования позволяют аппроксимировать временной ряд нелинейной зависимостью. Причем процесс построения нейросетевой модели (определение состава входных переменных, числа слоев и количества нейронов в слоях, выбор функций активации нейронов, определение оптимальных значений весов связей нейронов) позволяет получить прогнозную модель в виде аналитической нелинейной зависимости.

Одним из ключевых моментов при построении нейросетевых моделей в различных прикладных областях, влияющих на ее адекватность, является определение состава ее входных переменных. Состав входных переменных традиционно выбирается из некоторых физических соображений или методом подбора. Для задачи определения состава входных переменных прогнозной нейросетевой модели временного ряда предлагается использовать особенности поведения автокорреляционной и частной автокорреляционной функций.

В работе предлагается метод определения состава входных переменных нейросетевых моделей для стационарных и нестационарных временных рядов, базирующийся на построении и анализе автокорреляционных функций. На основе предложенного метода разработаны алгоритм и программа в среде программирования Python, определяющая состав входных переменных прогнозной нейросетевой модели — перцептрона, а также строящая саму модель. Осуществлена экспериментальная апробация предложенного метода на примере построения прогнозной нейросетевой модели временного ряда, отражающего потребление электроэнергии в разных регионах США, открыто опубликованной компанией PJM Interconnection LLC (PJM) — региональной сетевой организацией в Соединенных Штатах. Данный временной ряд является нестационарным и характеризуется наличием как тренда, так и сезонности. Прогнозирование очередных значений временного ряда на основе предыдущих значений и построенной нейросетевой модели показало высокую точность аппроксимации, что доказывает эффективность предлагаемого метода.

Ключевые слова: временной ряд, прогнозирование, нейросетевая модель, перцептрон, тренд, сезонность, стационарный ряд, нестационарный ряд, автокорреляционная функция, частная автокорреляционная функция, точность аппроксимации

Работа выполнена при финансовой поддержке Министерства образования и науки РФ в рамках государственного задания по проекту № 8.6141.2017/8.9.

© 2020 Лилия Юнеровна Емалетдинова, Зульфат Ильгизарович Мухаметзянов,
Дина Владимировна Катасёва, Айгуль Надилевна Кабирова

Статья доступна по лицензии Creative Commons Attribution-NoDerivs 3.0 Unported License.

Чтобы получить текст лицензии, посетите веб-сайт <http://creativecommons.org/licenses/by-nd/3.0/>
или отправьте письмо в Creative Commons, PO Box 1866, Mountain View, CA 94042, USA.

UDC: 004.89

A method of constructing a predictive neural network model of a time series

L. Yu. Emaletdinova^a, Z. I. Mukhametzyanov^b,
D. V. Kataseva^c, A. N. Kabirova^d

Kazan National Research Technical University named after A. N. Tupolev,
10 K. Marx st., Kazan, 420111, Russia

E-mail: ^alilia@stcline.ru, ^bbanderos25z@gmail.com, ^c415pisarevad@mail.ru, ^dkabirovaaigul@mail.ru

Received 19.01.2020, after completion — 18.04.2020.

Accepted for publication 06.05.2020.

This article studies a method of constructing a predictive neural network model of a time series based on determining the composition of input variables, constructing a training sample and training itself using the back propagation method. Traditional methods of constructing predictive models of the time series are: the autoregressive model, the moving average model or the autoregressive model — the moving average allows us to approximate the time series by a linear dependence of the current value of the output variable on a number of its previous values. Such a limitation as linearity of dependence leads to significant errors in forecasting.

Mining Technologies using neural network modeling make it possible to approximate the time series by a non-linear dependence. Moreover, the process of constructing of a neural network model (determining the composition of input variables, the number of layers and the number of neurons in the layers, choosing the activation functions of neurons, determining the optimal values of the neuron link weights) allows us to obtain a predictive model in the form of an analytical nonlinear dependence.

The determination of the composition of input variables of neural network models is one of the key points in the construction of neural network models in various application areas that affect its adequacy. The composition of the input variables is traditionally selected from some physical considerations or by the selection method. In this work it is proposed to use the behavior of the autocorrelation and private autocorrelation functions for the task of determining the composition of the input variables of the predictive neural network model of the time series.

In this work is proposed a method for determining the composition of input variables of neural network models for stationary and non-stationary time series, based on the construction and analysis of autocorrelation functions. Based on the proposed method in the Python programming environment are developed an algorithm and a program, determining the composition of the input variables of the predictive neural network model — the perceptron, as well as building the model itself. The proposed method was experimentally tested using the example of constructing a predictive neural network model of a time series that reflects energy consumption in different regions of the United States, openly published by PJM Interconnection LLC (PJM) — a regional network organization in the United States. This time series is non-stationary and is characterized by the presence of both a trend and seasonality. Prediction of the next values of the time series based on previous values and the constructed neural network model showed high approximation accuracy, which proves the effectiveness of the proposed method.

Keywords: time series, forecasting, neural network model, perceptron, trend, seasonality, stationary series, non-stationary series, autocorrelation function, private autocorrelation function, approximation accuracy

Citation: *Computer Research and Modeling*, 2020, vol. 12, no. 4, pp. 737–756 (Russian).

The work was supported by the Russian Federation Ministry of Education and Science, project No. 8.6141.2017/8.9.

1. Введение

В настоящее время задача прогнозирования функционального состояния сложных систем на основе анализа временного ряда является актуальной в различных областях человеческой деятельности: в медицине, экономике, политике, технических областях [Ахатов, Назаров, 2018; Зуева и др., 2017; Проталинский и др., 2019]. Анализ временного ряда позволяет выявлять закономерности динамики изменения его значений и оценить значение показателя, описываемого временным рядом, в будущем. Использование результатов прогнозирования позволяет уменьшить риск принятия необоснованных управленческих решений [Ткалич и др., 2016].

Традиционно для решения задачи прогнозирования используются классические модели. Для анализа стационарных процессов используются: авторегрессионная модель $AR(p)$, модель скользящего среднего $MA(q)$ или модель авторегрессии — скользящего среднего $ARMA(p, q)$. Здесь p, q — параметры моделей. Для нестационарных процессов: интегрированная модель авторегрессии скользящего среднего $ARIMA(p, d, q)$ или сезонная интегрированная модель авторегрессии — скользящего среднего $SARIMA(p, d, q) (P_s, D_s, Q_s)$. Здесь d — порядок разности временного ряда, P_s — параметр авторегрессионной сезонной составляющей, Q_s — параметр сезонной составляющей скользящего среднего, D_s — порядок разности сезонной составляющей, s — размерность сезонности (квартал, месяц и т. д.) [Селиверстова, 2016].

Необходимо отметить, что в связи со случайностью и периодичностью данных традиционные модели прогнозирования в некоторых случаях не способны уловить особенности данных и показывают плохие результаты. Поэтому исследователями предлагаются различные подходы и методы для повышения точности и стабильности прогнозирования. В работе [Jiang et al., 2019] с этой целью предложена новая гибридная система прогнозирования, состоящая из трех модулей (модуль шумоподавления, модуль оптимизации и модуль прогнозирования). Подход, изложенный в работе [Nguyen, Novak, 2019], основан на методах нечеткой логики. В работе учитывается, что временные ряды могут быть аддитивно разложены на трендовую и сезонную составляющие, могут быть выделены нерегулярные колебания, и поэтому прогнозирование представляет собой комбинацию индивидуального прогнозирования каждого из этих составляющих.

Классические модели прогнозирования $AR(p)$, $MA(q)$, $ARMA(p, q)$, $ARIMA(p, d, q)$, $SARIMA(p, d, q) (P_s, D_s, Q_s)$ являются линейными функциями от некоторой совокупности предыдущих значений временного ряда. Коэффициенты в данных моделях определяются на основе использования исходного временного ряда. Однако нейронные сети, которые являются аппроксиматорами нелинейных функций, можно использовать, заменив линейный вид классических моделей прогнозирования на нелинейный [Емалетдинова, Мухаметзянов, 2019; Колмаков и др., 2016; Jinu, 2019; Singhal, Swarup, 2011; Tealab et al., 2017; Zulifqar et al., 2017]. Для использования нейросетевой модели прогнозирования необходимо прежде всего определить вид и архитектуру сети, затем ее параметры с использованием обучающей выборки, построенной на основе значений исходного временного ряда. Для задач прогнозирования, как правило, используются сети прямого распространения или рекуррентные сети [Бильгаева, Власов, 2017; Киселев и др., 2018; Шепелев и др., 2016; Шолтанюк, 2019; Якупов, Рожко, 2017; Vandara et al., 2020; Kumar et al., 2004].

Для определения структуры сети часто используется генетический алгоритм [Захаров и др., 2015]. Для формирования состава входных переменных также может использоваться генетический алгоритм [Катасёв, 2019], однако такой подход требует значительных вычислительных затрат.

Для определения состава входных переменных нейронной сети, как нелинейной прогнозной модели, целесообразно использовать методики, которые используются при построении классической линейной прогнозной модели, а именно: автокорреляционные (АКФ) и частные автокорреляционные функции (ЧАКФ) [Трегуб, Трегуб, 2011]. Из теории анализа стационар-

ных временных рядов известно, что если на графике АКФ наблюдается плавное затухание коэффициентов автокорреляции с ростом лага, а на графике ЧАКФ — резкое уменьшение значений частных коэффициентов автокорреляции до нулевого или близкого к нулю значений, то в качестве порядка p модели авторегрессии $AR(p)$ выбирают лаг, после которого все коэффициенты ЧАКФ имеют незначительную величину. Если на графике АКФ наблюдается резкое уменьшение значений коэффициентов автокорреляции до нулевого или близкого к нулю значений, а на графике ЧАКФ — плавное затухание частных коэффициентов автокорреляции с ростом лага, то в качестве порядка q модели скользящего среднего $MA(q)$ выбирают лаг, после которого все коэффициенты АКФ имеют незначительную величину. Если наблюдается плавное затухание и тех и других коэффициентов, то для описания стационарного процесса применяется, как правило, комбинированная интегрированная модель авторегрессии и скользящего среднего $ARMA(p, q)$. Здесь в качестве порядка p и q модели выбирают лаги, после которых все коэффициенты АКФ и ЧАКФ имеют незначительную величину [Трегуб, Трегуб, 2011].

Нестационарный процесс с помощью достаточно несложных преобразований приводится к стационарному процессу. Одним из таких способов преобразования является взятие конечных разностей. На основе анализа АКФ и ЧАКФ преобразованного ряда определяются параметры модели авторегрессии и скользящего среднего $SARIMA(p, d, q)$ (P_s, D_s, Q_s) или $ARIMA(p, d, q)$ соответственно при наличии или отсутствии сезонности.

Полученные значения параметров классических моделей временного ряда определяют количество используемых в модели предыдущих значений ряда, начиная от текущего значения, и/или число предыдущих случайных его ошибок. Причем в этих моделях значение временного ряда в текущий момент зависит линейно от предыдущих значений этого же ряда или случайных его ошибок. В отличие от этого в нейросетевой модели значение временного ряда в текущий момент будет зависеть нелинейно от предыдущих значений этого же ряда.

Целью статьи является развитие методов нейросетевого прогнозирования временных рядов и предварительной подготовки данных к этому моделированию.

Основными задачами, подлежащими к решению в данной работе, являются:

- 1) определение состава входных переменных прогнозной нейросетевой модели (общее число входных переменных и перечень предыдущих значений исходного временного ряда в качестве входных переменных) в зависимости от типа исходного временного ряда;
- 2) формирование обучающей выборки для прогнозной нейросетевой модели на основе исходного ряда и состава входных переменных.

Предлагается следующий метод построения нейросетевой модели на основе анализа поведения АКФ и ЧАКФ.

2. Метод построения прогнозной нейросетевой модели временного ряда

1. Осуществить декомпозицию временного ряда, выделив трендовую, сезонную и шумовую составляющие одним из известных методов [Афанасьев, Юзбашев, 2001].

2. Проверить ряд на стационарность, например, с помощью теста Дикки Фулера.

3. Если ряд является стационарным, т. е. трендовая и сезонная составляющие отсутствуют, то на основе анализа графиков АКФ и ЧАКФ определить параметры p, q . Здесь p и q — параметры модели, которые определяются по ЧАКФ и АКФ соответственно и равны числу лагов, для которых коэффициент корреляции наиболее значимый.

4. Если ряд является нестационарным, имеет тренд, но сезонность отсутствует, то необходимо его преобразовать методом конечных разностей. Порядок разности d считается определенным в том случае, если при взятии разности порядка d исходный нестационарный ряд становится стационарным. Определить параметры p и q , используя АКФ и ЧАКФ стационарного ряда, полученного после преобразования.

5. Если ряд является нестационарным, имеет тренд и присутствует сезонность, то необходимо его преобразовать к стационарному виду методом конечных разностей не только для текущих значений временного ряда, но и для его сезонных составляющих. Порядок разности d и порядок разности сезонной составляющей D_s считаются определенными в том случае, когда при взятии разности порядка D , а затем порядка d , исходный нестационарный ряд становится стационарным. Первые P_s лагов в ЧАКФ преобразованного ряда, отличные от нуля и повторяющиеся через период s , определяют порядок сезонной составляющей авторегрессии. Первые Q_s лагов в АКФ ряда, отличные от нуля и повторяющиеся через период s , определяют порядок сезонной составляющей скользящего среднего.

6. Определить вид нейросетевой модели:

а) в случае стационарности временного ряда

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-n}),$$

где $n = \max(p, q)$, а параметры p и q определены на основании АКФ и ЧАКФ исходного временного ряда;

б) в случае нестационарности временного ряда и отсутствия сезонности

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-n}),$$

где $n = \max(p, q)$, а параметры p и q определены на основании АКФ и ЧАКФ временного ряда, преобразованного к стационарному виду методом конечных разностей;

с) в случае нестационарности временного ряда при наличии сезонности

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-n}, y_{t-s-1}, y_{t-s-2}, \dots, y_{t-s-n}, \dots, y_{t-ms-1}, y_{t-ms-2}, \dots, y_{t-ms-n}, u_t),$$

где $n = \max(p, q)$, $m = \max(P_s, Q_s)$, s — период сезонности, u_t — индекс сезонности, вычисляемый на основе исходного временного ряда по формуле

$$u_t = \frac{Y_{st}}{Y_{s0}},$$

здесь $Y_{st} = \frac{\sum_{i=1}^k Y_{it}}{k}$ — средняя по каждому внутрисезонному периоду t (например, месяцу) для всех k сезонов (например, годов),

$$Y_{s0} = \frac{\sum_{i=1}^k \sum_{t=1}^p Y_{it}}{kp}$$
 — общая средняя по всем сезонам (k) и внутрисезонным периодам (p),

Y_{it} — значение временного ряда для внутрисезонного периода t (например, месяца) и для текущего сезона i (например, года).

Параметры p , q , P_s , Q_s определены на основании АКФ и ЧАКФ временного ряда, преобразованного к стационарному методу конечных разностей соответственно для текущих значений временного ряда и для его сезонных составляющих.

7. Сформировать обучающую выборку на основе значений исходного временного ряда:

а) для модели вида $y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-n})$ выборка формируется как

$$\{(y_{t-n}, \dots, y_{t-2}, y_{t-1}, y_t), \quad t = \overline{n+1, L}\};$$

б) для модели вида

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-n}, y_{t-s-1}, y_{t-s-2}, \dots, y_{t-s-n}, \dots, y_{t-ms-1}, y_{t-ms-2}, \dots, y_{t-ms-n}, u_t)$$

выборка формируется как

$$\{(y_{t-ms-n}, \dots, y_{t-ms-2}, y_{t-ms-1}, \dots, y_{t-s-n}, \dots, y_{t-s-2}, y_{t-s-1}, y_{t-n}, \dots, y_{t-2}, y_{t-1}, u_t, y_t), \quad t = \overline{ms+n+1, L}\}.$$

Здесь параметр L равен максимальному количеству данных (строк), которые есть в исходной выборке.

8. Определить число слоев, количество нейронов в слоях и обучить нейронную сеть прямого распространения (персептрон) методом обратного распространения ошибки.

3. Пример построения прогнозной нейросетевой модели

На основе предложенного метода был разработан алгоритм, реализованный средствами программирования Python, который был апробирован при построении нейросетевой модели для прогнозирования потребления электроэнергии.

Временной ряд представляет собой данные о почасовом потреблении электроэнергии (МВт) в регионах США. Данные предоставлены компанией PJM Interconnection LLC (PJM) — региональная сетевая организация в Соединенных Штатах. Данные представлены с 1 января 2005 года по 3 августа 2018 года, всего имеются 119 тысяч строк: дата, время, величина энергопотребления. Для визуального анализа ряда была произведена аддитивная декомпозиция ряда с помощью библиотеки statsmodels программного средства Python. На рис. 1 представлен фрагмент декомпозиции ряда за 1 месяц.

Построим автокорреляционные (АКФ) (рис. 2, а) и частные автокорреляционные (ЧАКФ) (рис. 2, б) функции исходного временного ряда.

Анализ декомпозиции (рис. 1) показал, что ряд характеризуется наличием тренда переменного характера с возрастанием и убыванием и наличием сезонности — 24 часа. Анализ графиков АКФ и ЧАКФ (рис. 2) показывает, что признаки стационарности ряда отсутствуют.

Согласно пункту б.с) вышеизложенного метода «Построение прогнозной нейросетевой модели временного ряда», для такого рода нестационарного ряда с наличием тренда и сезонности, нейросетевая модель будет реализовать зависимость вида

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-n}, y_{t-s-1}, y_{t-s-2}, \dots, y_{t-s-n}, \dots, y_{t-ms-1}, y_{t-ms-2}, \dots, y_{t-ms-n}, u_t).$$

Для того чтобы определить значения n , s , m зависимости, используем известную в научной литературе методику приведения временного ряда к стационарному виду.

Поскольку временной ряд характеризуется сезонностью 24 часа, то была вычислена сезонная разность 1 порядка и осуществлена его декомпозиция (рис. 3) с выделением трендовой, сезонной и шумовой составляющих. Анализ графиков показал, что тренд и сезонность все еще наблюдаются.

При преобразовании полученного на предыдущем шаге ряда с помощью обычной разности 1 порядка и осуществлении его декомпозиции (рис. 4) стало очевидно, что удалось избавиться от тренда, а сезонная компонента стала близка к 0. То есть исходный ряд после последовательного взятия сезонной и обычной разностей стал обладать свойством стационарности.

Для определения параметров p , q , P , Q построим и проанализируем АКФ (рис. 5, а) и ЧАКФ (рис. 5, б) стационарного ряда, полученного в результате преобразований (взятия сезонной и обычной разностей).

Анализ АКФ и ЧАКФ показал, что в качестве значений параметров можно рассмотреть $p = 1$, $q = 3$, а сезонных параметров — $P = 4$ и $Q = 2$.

Ввиду того что исходный временной ряд является нестационарным, а также содержит сезонную компоненту, необходимо рассматривать соответствующую нейросетевую модель временного ряда в виде

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-n}, y_{t-s-1}, y_{t-s-2}, \dots, y_{t-s-n}, \dots, y_{t-ms-1}, y_{t-ms-2}, \dots, y_{t-ms-n}, u_t)$$

и обучающую выборку в виде

$$\{(y_{t-ms-n}, \dots, y_{t-ms-2}, y_{t-ms-1}, \dots, y_{t-s-n}, \dots, y_{t-s-2}, y_{t-s-1}, y_{t-n}, \dots, y_{t-2}, y_{t-1}, u_t, y_t), \quad t = \overline{ms + n + 1, L}\},$$

которая формируется на основе исходного нестационарного ряда.

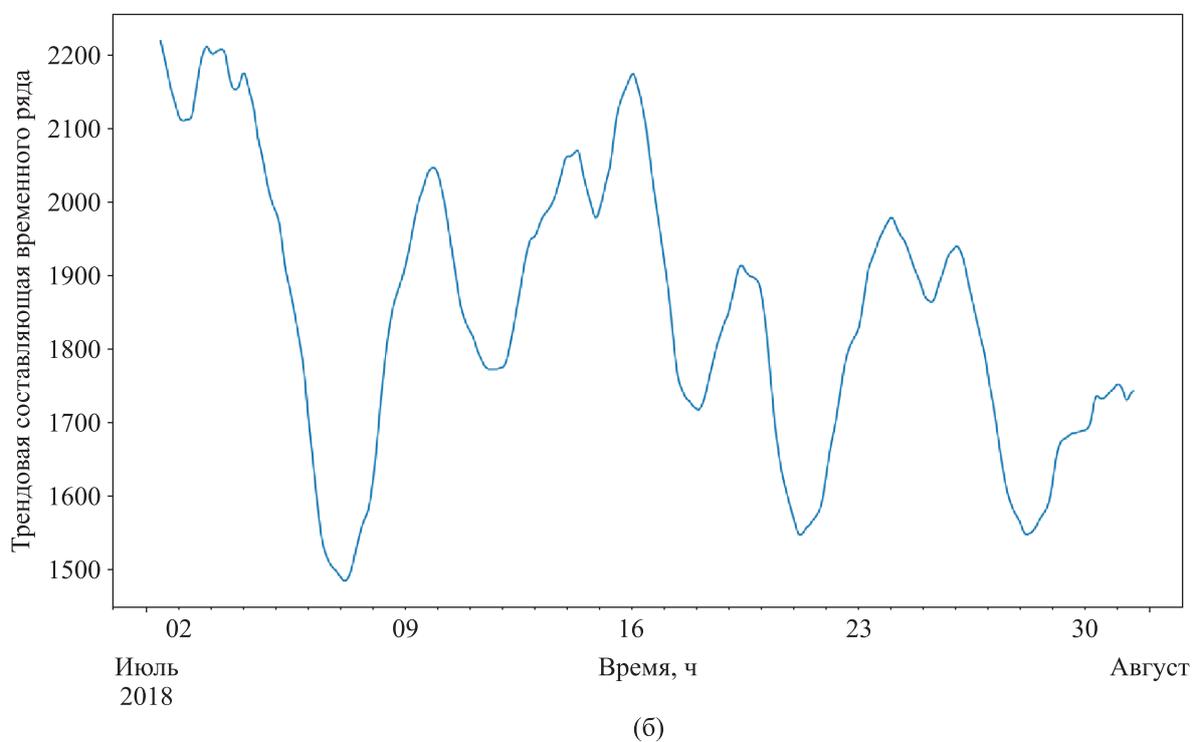
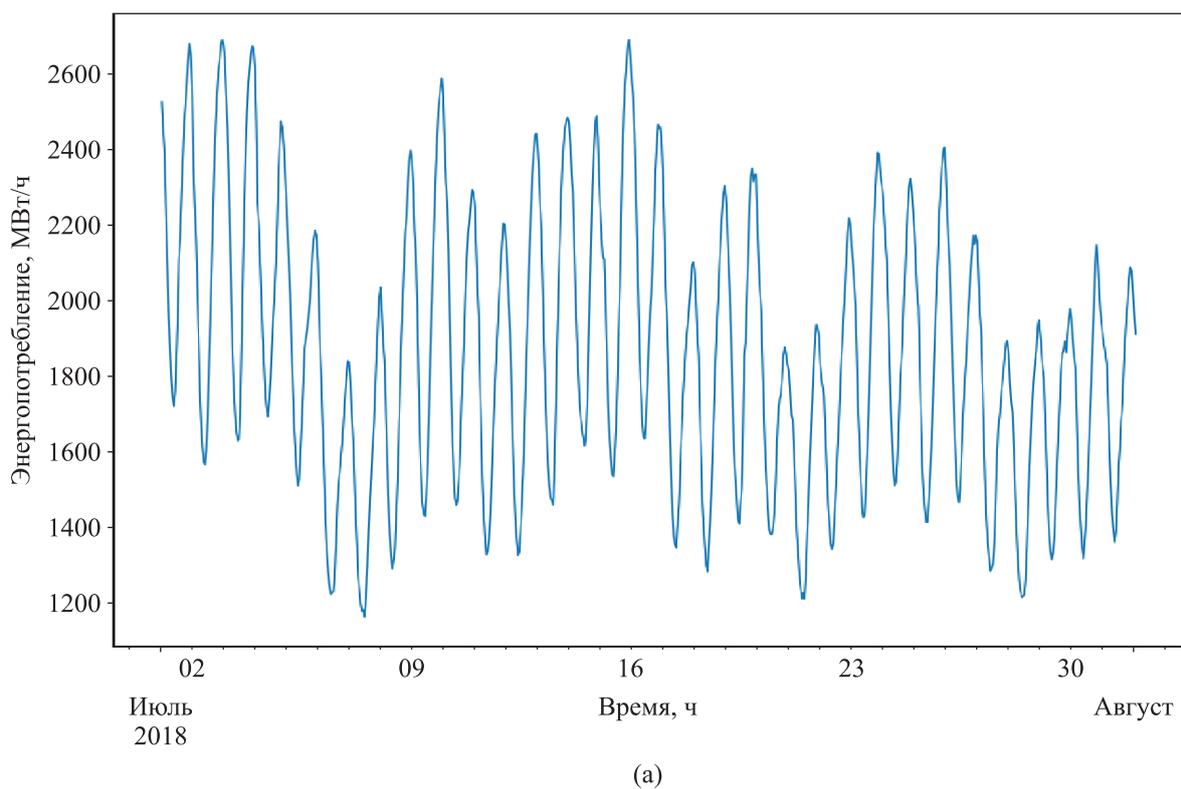


Рис. 1. Фрагменты результатов декомпозиции исходного ряда, полученные с помощью библиотеки statsmodels (Python): а) исходный временной ряд; б) трендовая составляющая временного ряда. Данные представлены за 1 месяц

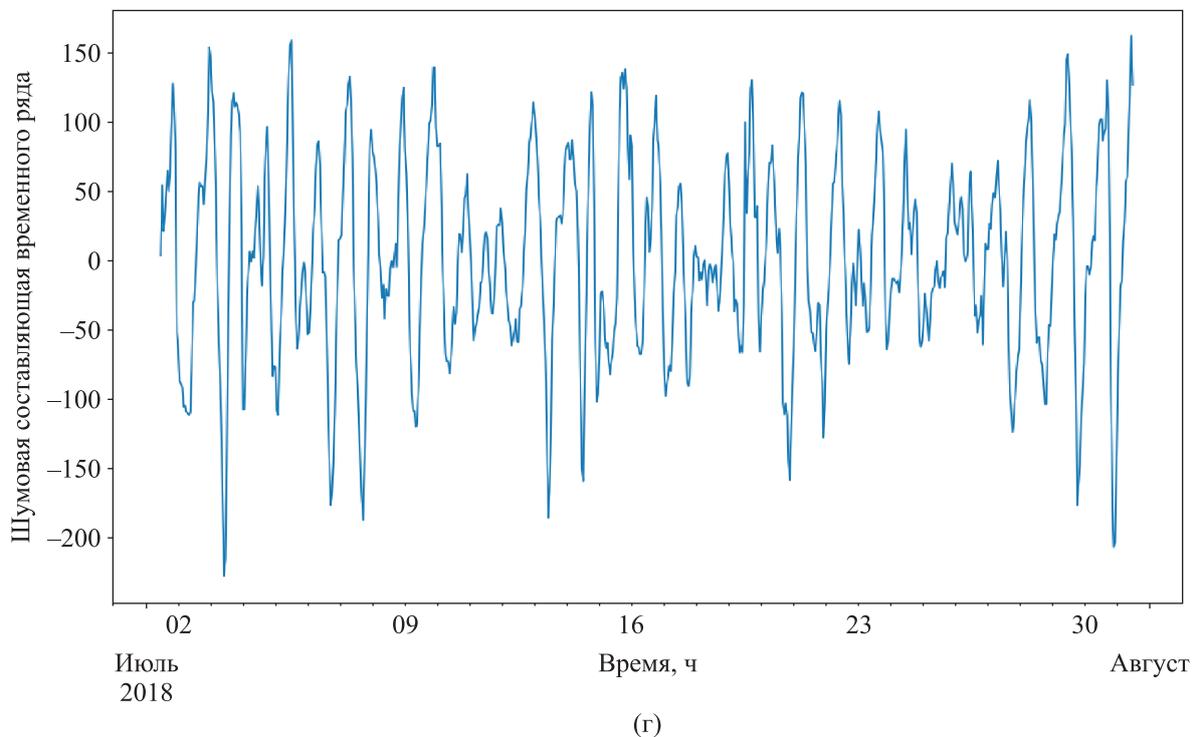
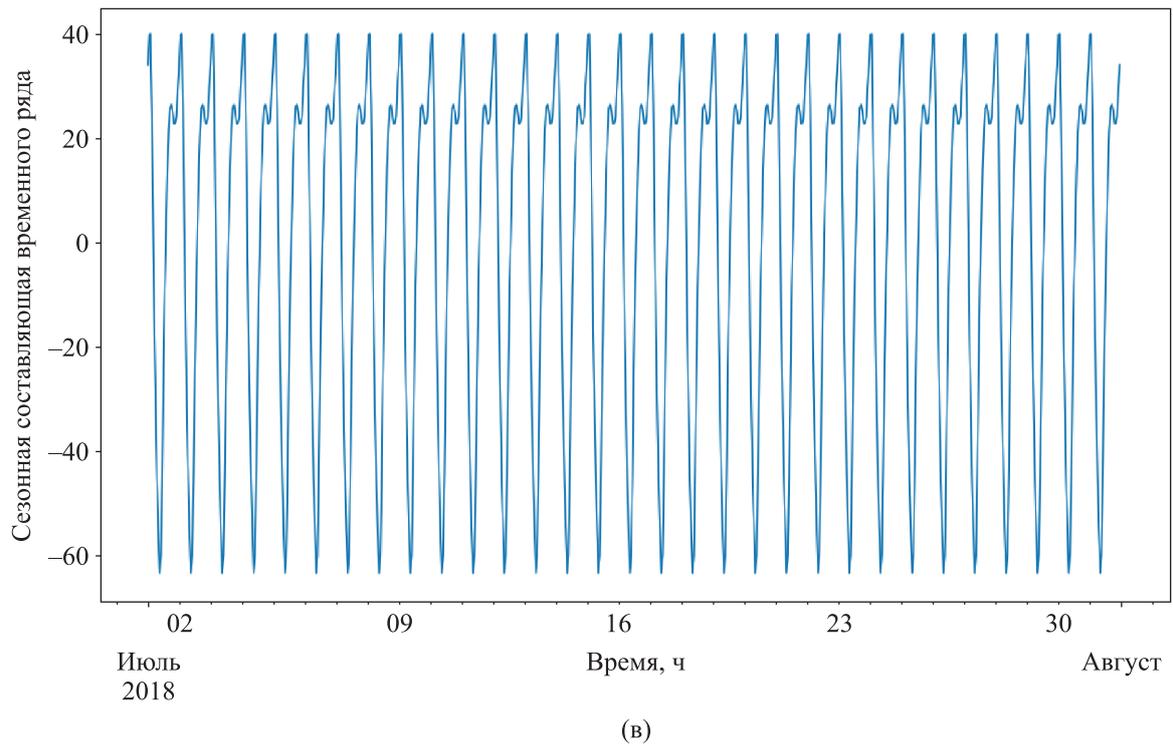
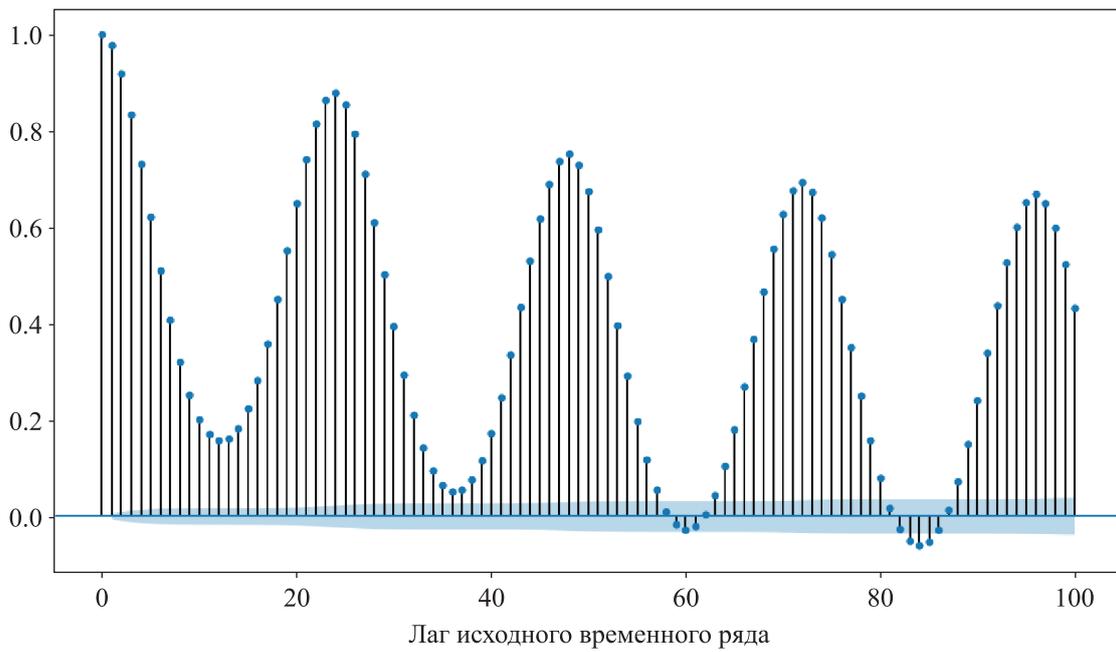
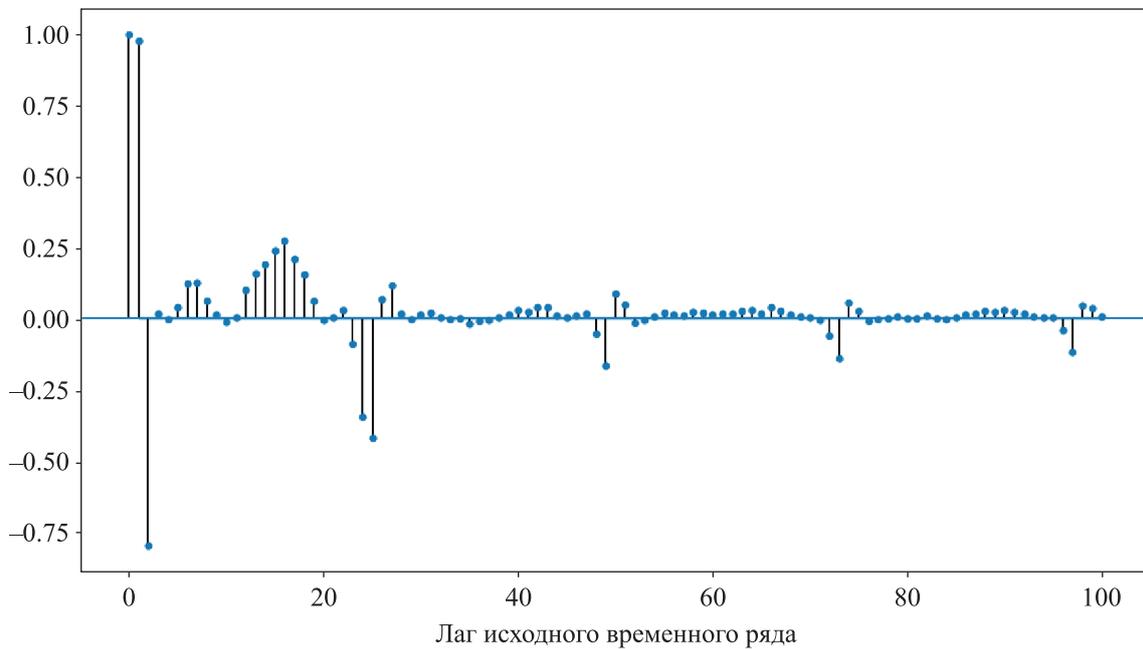


Рис. 1. Фрагменты результатов декомпозиции исходного ряда, полученные с помощью библиотеки statsmodels (Python): в) сезонная составляющая временного ряда; г) шумовая составляющая временного ряда. Данные представлены за 1 месяц (окончание)



(a)



(б)

Рис. 2. Автокорреляционная функция (а) и частная автокорреляционная функция (б) исходного ряда

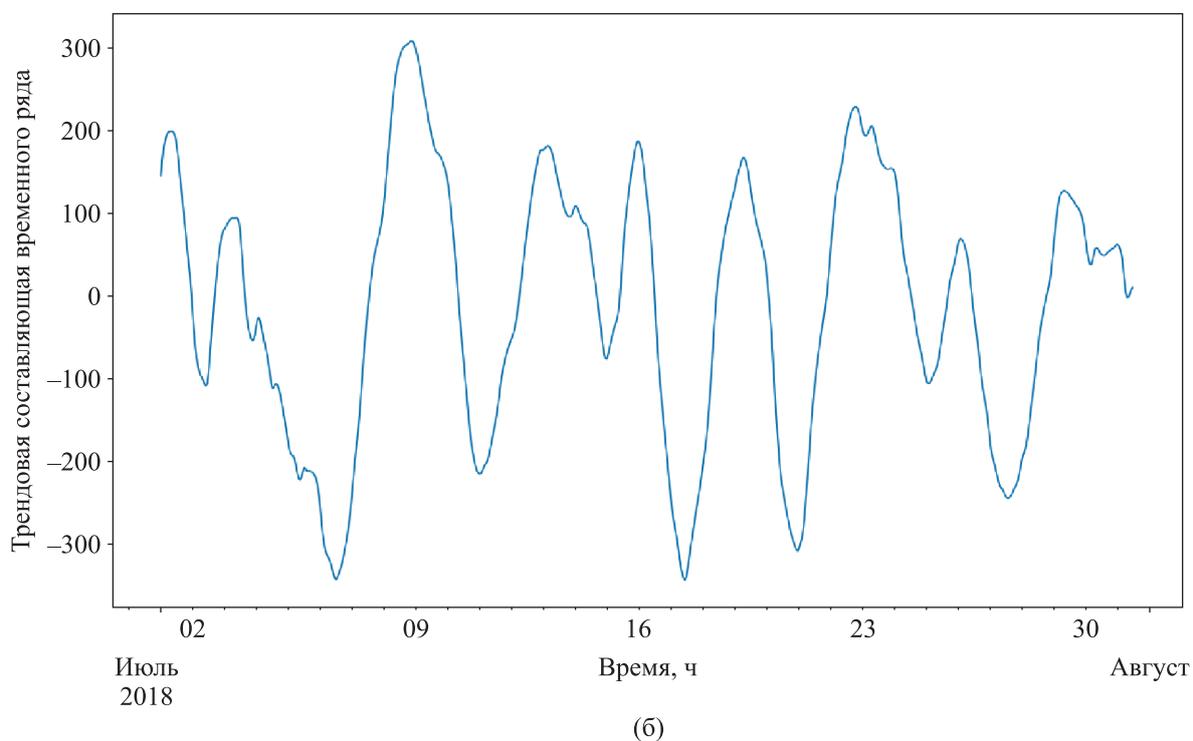
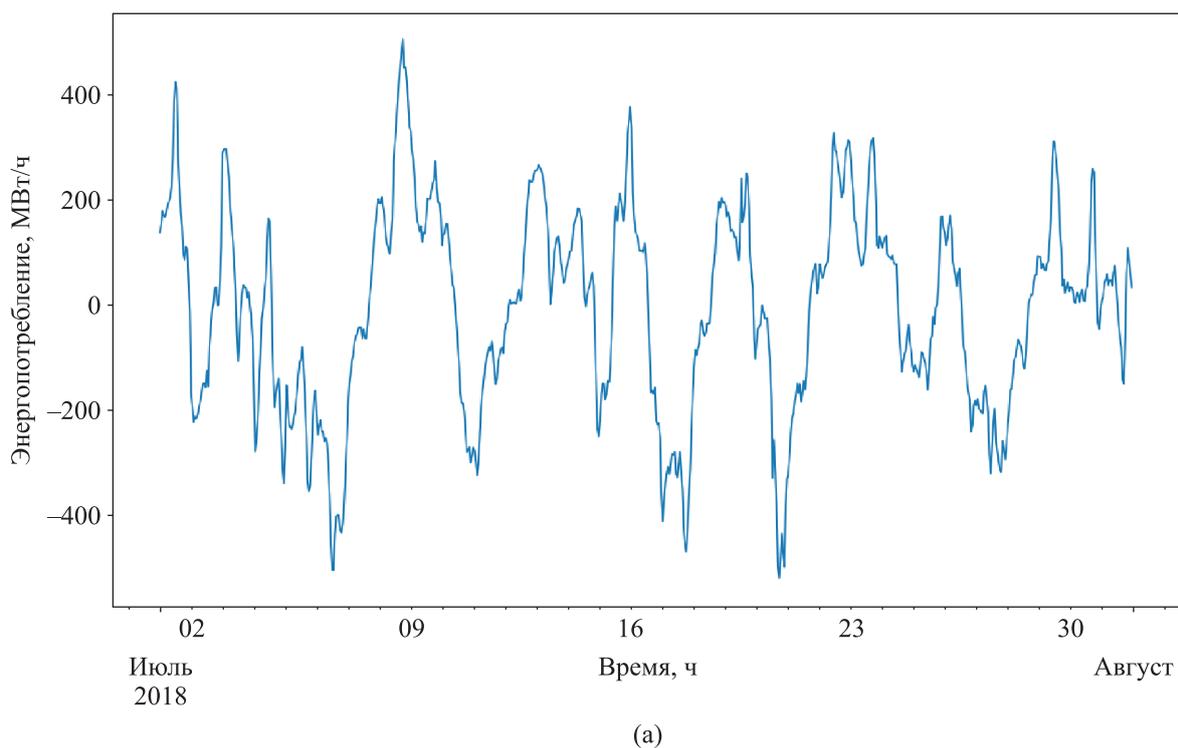
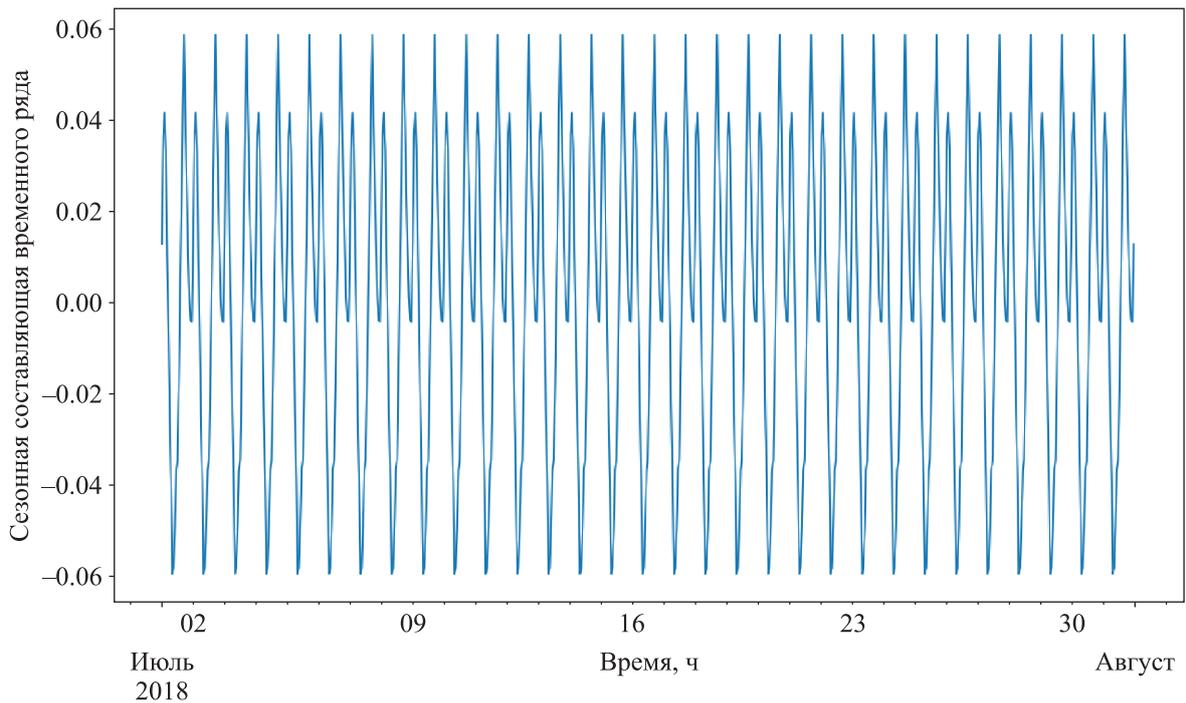
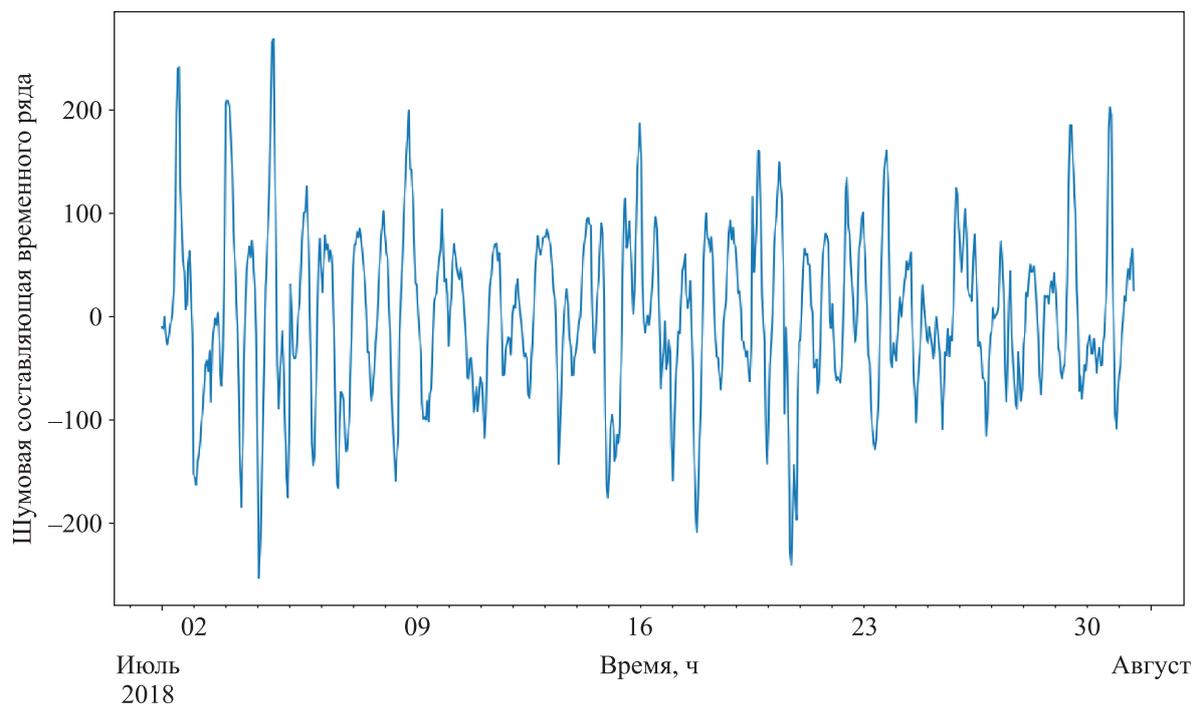


Рис. 3. Фрагменты результатов декомпозиции преобразованного ряда после взятия сезонной разности 1 порядка: а) временной ряд; б) трендовая составляющая временного ряда. Данные представлены за 1 месяц



(в)



(г)

Рис. 3. Фрагменты результатов декомпозиции преобразованного ряда после взятия сезонной разности 1 порядка: в) сезонная составляющая временного ряда; г) шумовая составляющая временного ряда. Данные представлены за 1 месяц (*окончание*)

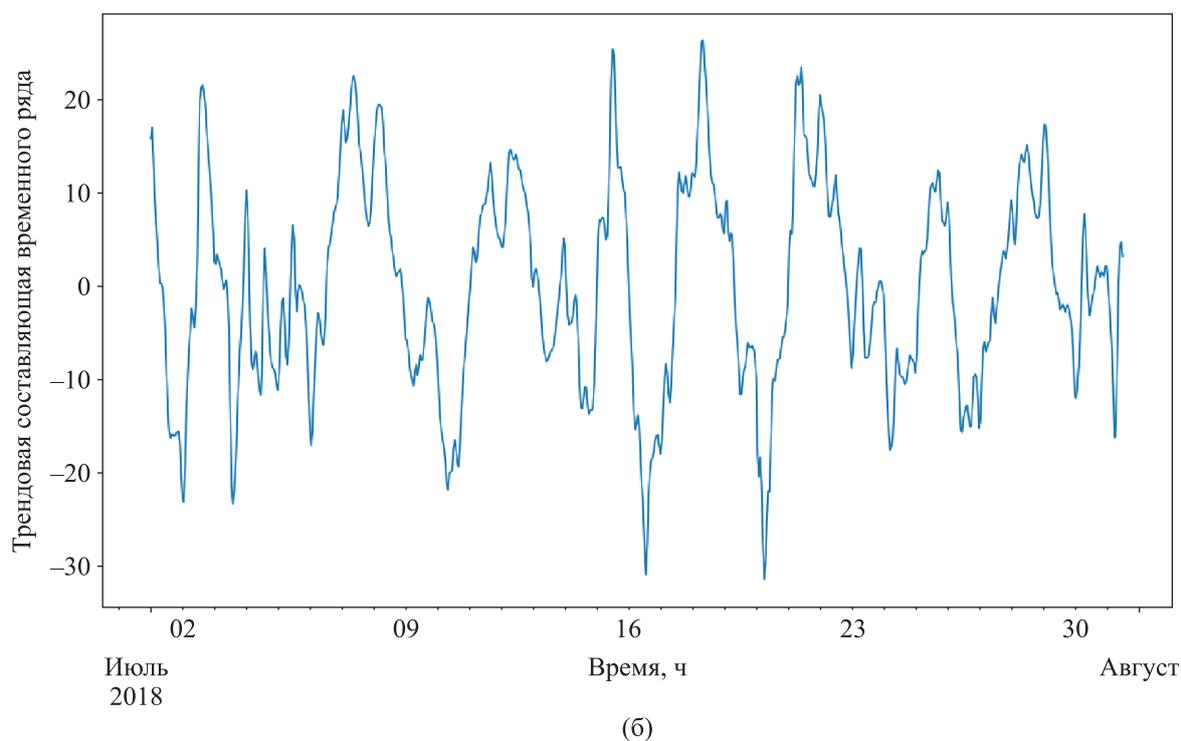
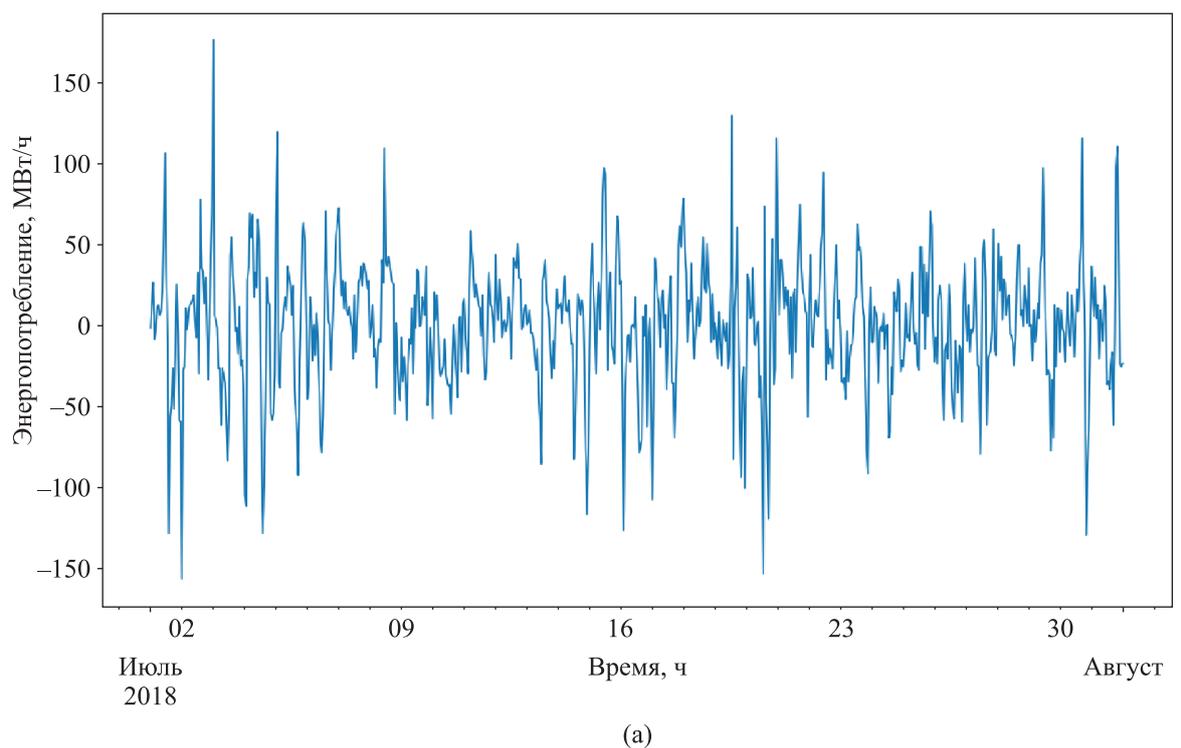


Рис. 4. Фрагменты результатов декомпозиции преобразованного ряда после взятия обычной разности 1 порядка: а) временной ряд; б) трендовая составляющая временного ряда. Данные представлены за 1 месяц

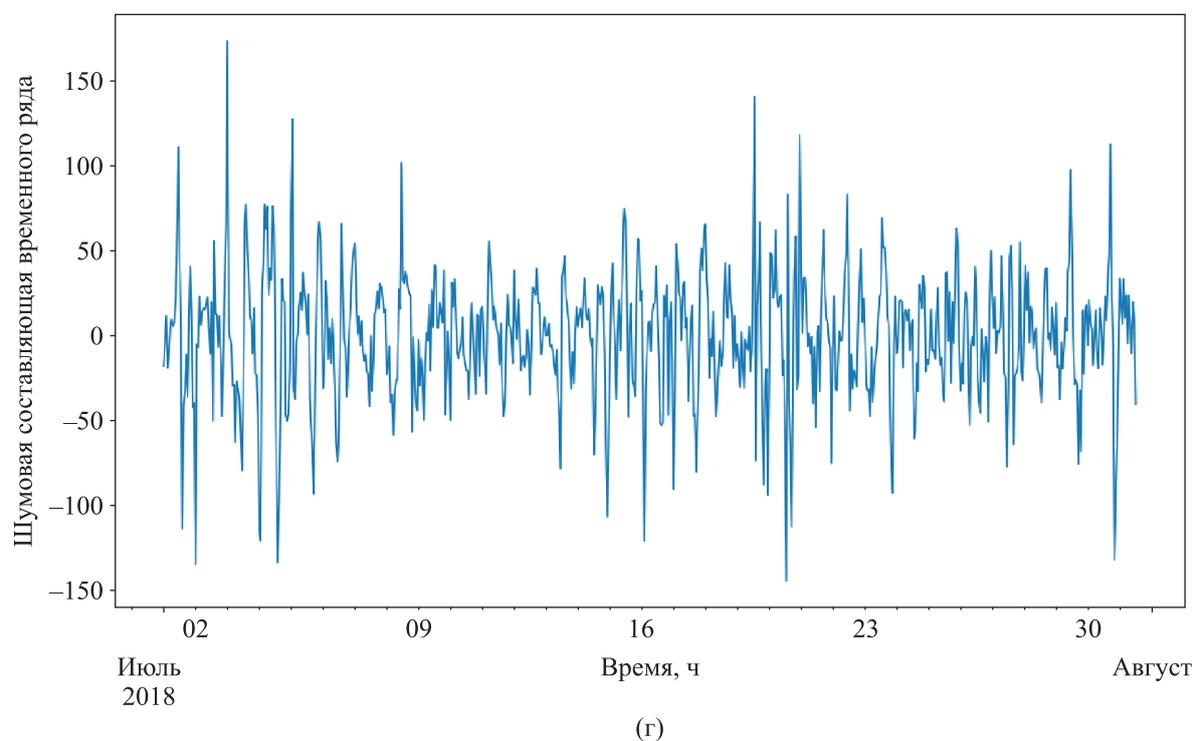
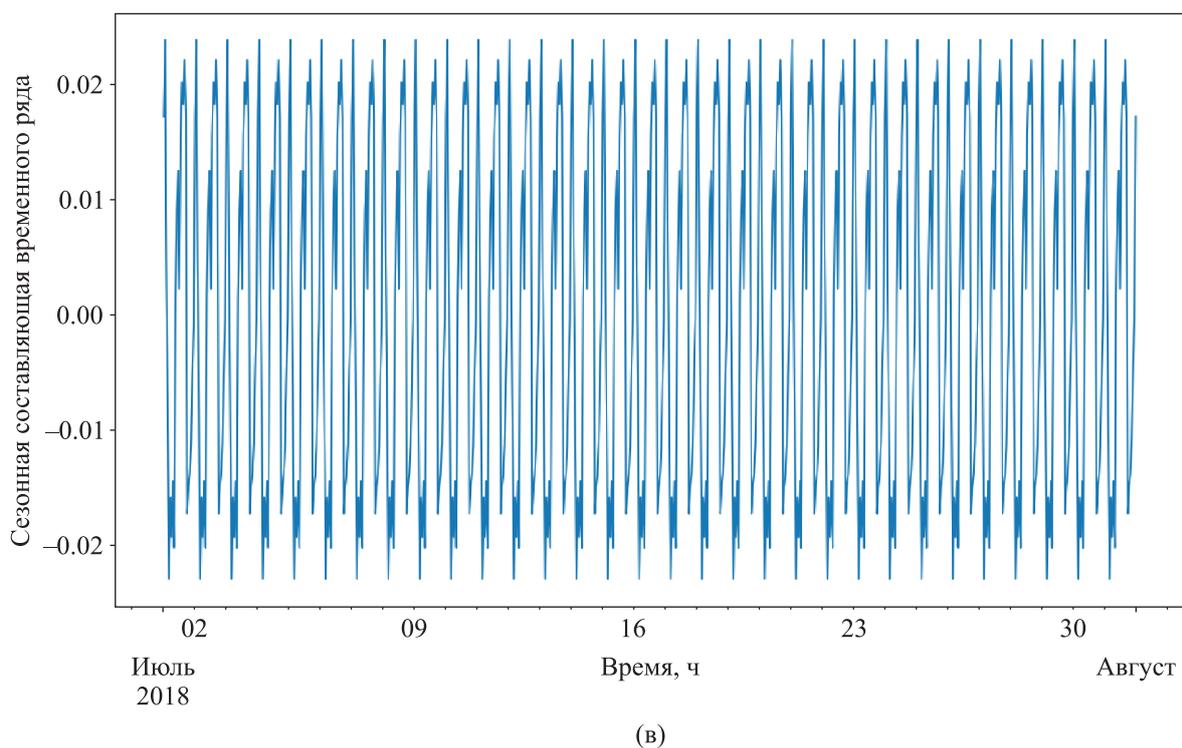
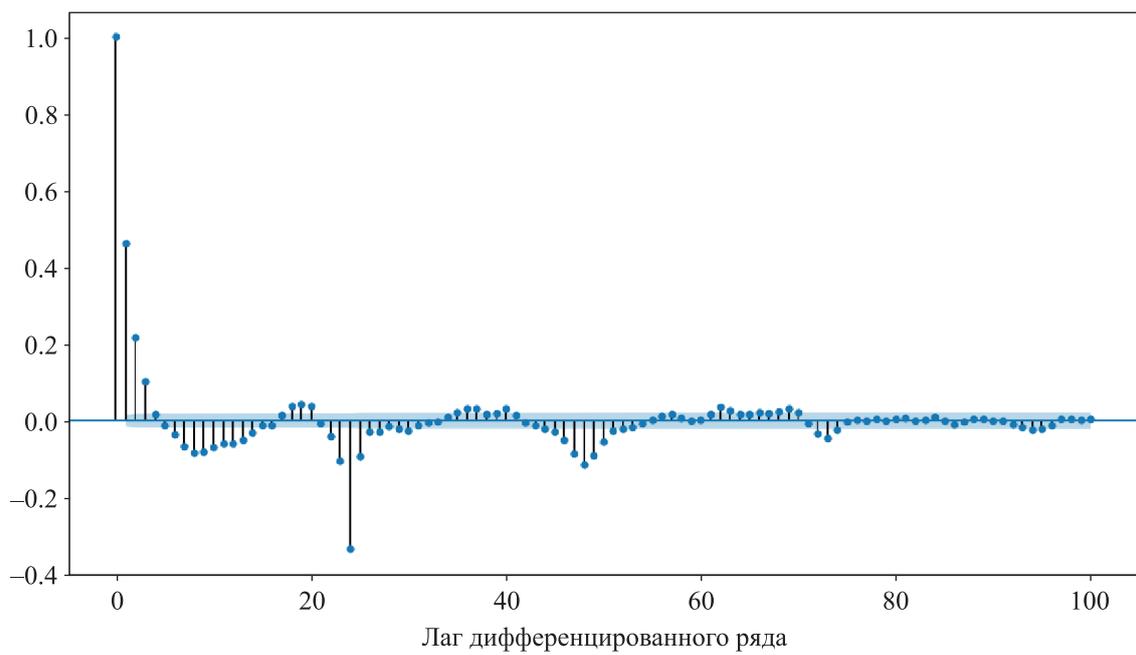
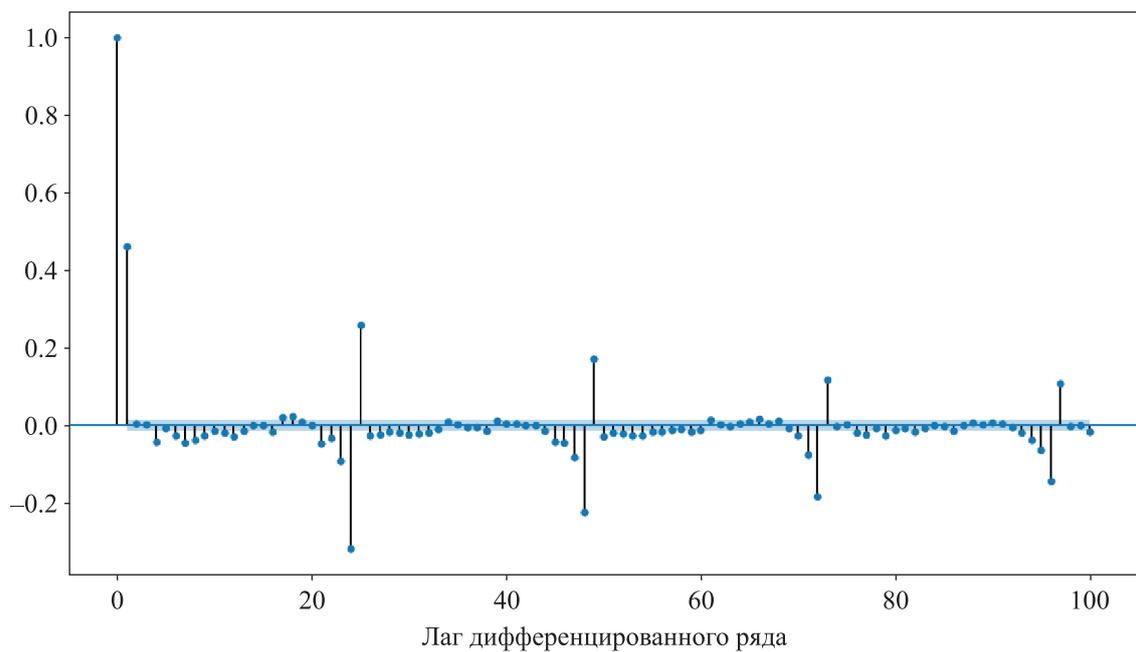


Рис. 4. Фрагмент результатов декомпозиции преобразованного ряда после взятия обычной разности 1 порядка: в) сезонная составляющая временного ряда; г) шумовая составляющая временного ряда. Данные представлены за 1 месяц (окончание)



(а)



(б)

Рис. 5. Автокорреляционная функция (а) и частная автокорреляционная функция (б) стационарного ряда, полученного после взятия сезонной и обычной разностей 1 порядка

Для построения данной модели был разработан алгоритм, позволяющий выбирать число внутренних слоев персептрона, количество нейронов в каждом слое, использующий для обучения сети метод обратного распространения ошибки. Алгоритм реализован средствами библиотеки Keras среды программирования Python [Шолле, 2018].

Для обучения модели были использованы 70 процентов из 119 тысяч строк данных, а оставшиеся 30 процентов использовались для тестирования обученной модели.

В результате работы программы была построена прогнозная нейросетевая модель (персептрон) со следующей структурой:

- входной слой содержит 13 входных переменных ($\max(p, q) \cdot \max(P, Q) = 3 \cdot 4 = 12$, также 1 входная переменная — индекс сезонности u_t);
- первый скрытый слой содержит 200 нейронов;
- второй скрытый слой содержит 250 нейронов;
- выходной слой содержит одну выходную переменную.

В качестве функции активации для скрытых слоев была использована функция LeakyReLU библиотеки Keras, которая реализует функцию вида $f(x) = \alpha \cdot x$ при $x < 0$ и $f(x) = x$ при $x \geq 0$, где α — малая константа. После каждого скрытого слоя был использован метод регуляризации dropout, позволяющий предотвратить переобучение сети на тренировочных данных. Для построенной нейронной сети коэффициенты регуляризации составили 0.01 и 0.02 для первого и второго слоя соответственно [Бартенев, 2019].

На рис. 6 представлен фрагмент графиков исходных тестовых и прогнозных значений временного ряда (непрерывной линией представлено тестовое значение, прерывистой линией — прогнозируемое нейросетевой моделью значение).

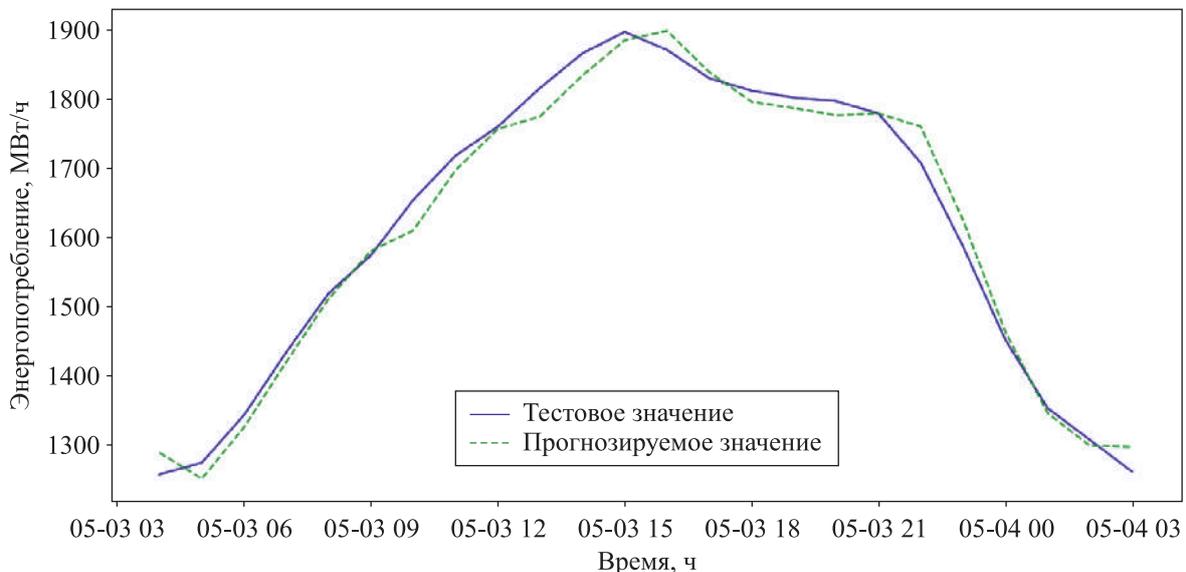


Рис. 6. Фрагмент результатов сравнения тестовых и прогнозируемых значений временного ряда, построенных нейросетевой моделью

Средняя ошибка прогноза на данных, используемых для обучения, составила 3 %, а на данных, используемых для тестирования, — 5 %.

Для оценки точности и адекватности построенной прогнозной нейросетевой модели была построена гистограмма остатков — разности прогнозных и исходных данных временного ряда (рис. 7). Из рисунка видно, что распределение остатков близко к нормальному виду.

Гипотеза о нормальном законе распределения с нулевым математическим ожиданием и средним квадратичным отклонением, равным 0.015, проверена и подтверждена критерием Колмогорова.

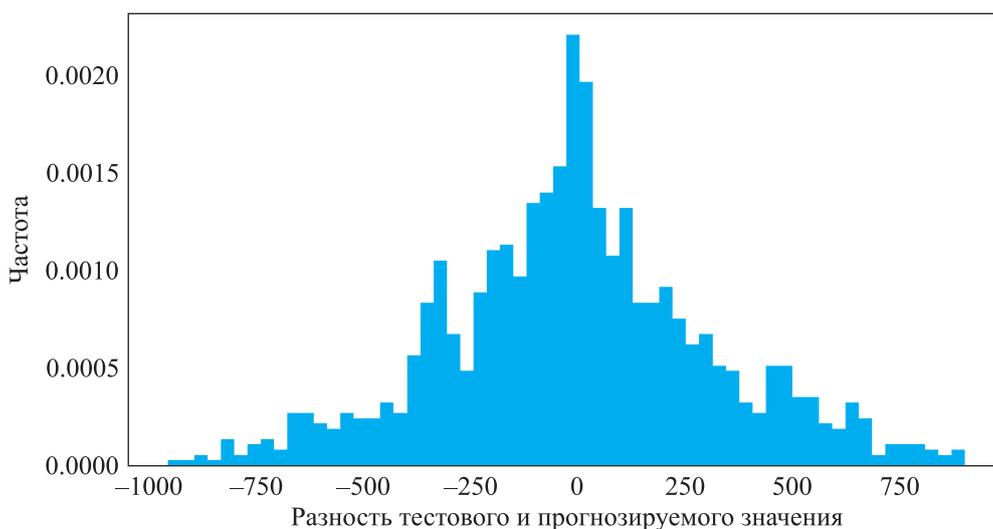


Рис. 7. Гистограмма остатков (разность прогнозных и исходных тестовых данных временного ряда)

Поскольку в рассматриваемом примере временного ряда исходный процесс является нестационарным и характеризуется сезонностью, то для сравнения результатов работы нейросетевой модели, являющейся универсальным нелинейным аппроксиматором, с классической моделью регрессионного прогноза была построена модель SARIMA (1, 1, 3) (4, 1, 2, 24), которая традиционно используется для прогнозирования таких процессов. Было осуществлено прогнозирование на данных, используемых как для обучения моделей, так и для их тестирования. На рис. 8 представлен фрагмент результатов сравнения исходных значений ряда, используемых для обучения модели SARIMA, и значений, прогнозируемых моделью SARIMA (1, 1, 3) (4, 1, 2, 24) (непрерывной линией представлено тренировочное значение, прерывистой линией — прогнозируемое моделью SARIMA значение).

На рис. 9 представлен фрагмент результатов сравнения исходных значений ряда, используемых для тестирования модели SARIMA, и значений, прогнозируемых моделью SARIMA (1, 1, 3) (4, 1, 2, 24) (непрерывной линией представлено тренировочное значение, прерывистой линией — прогнозируемое моделью SARIMA значение).

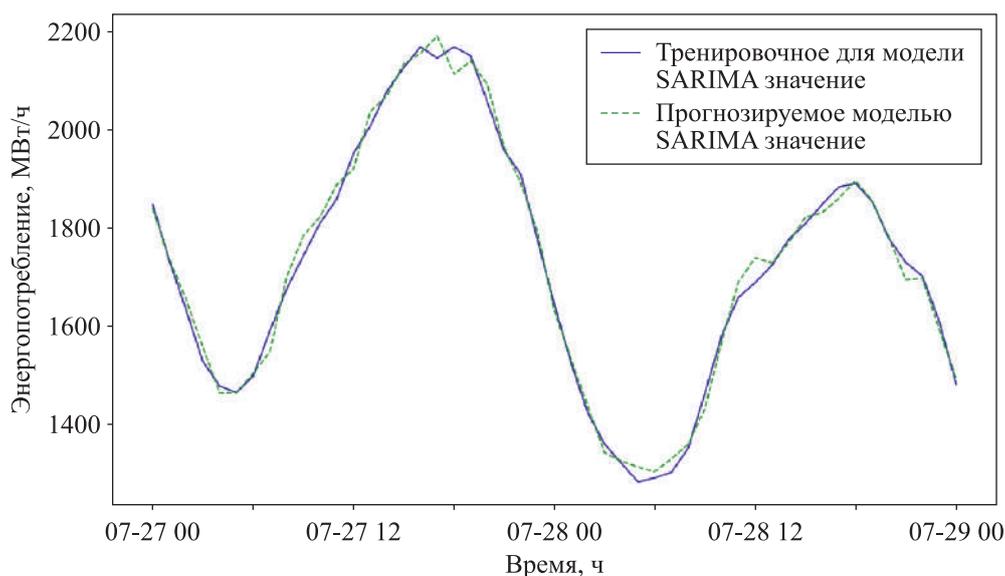


Рис. 8. Фрагмент результатов сравнения исходных значений, используемых для обучения модели SARIMA, и значений, прогнозируемых с ее помощью

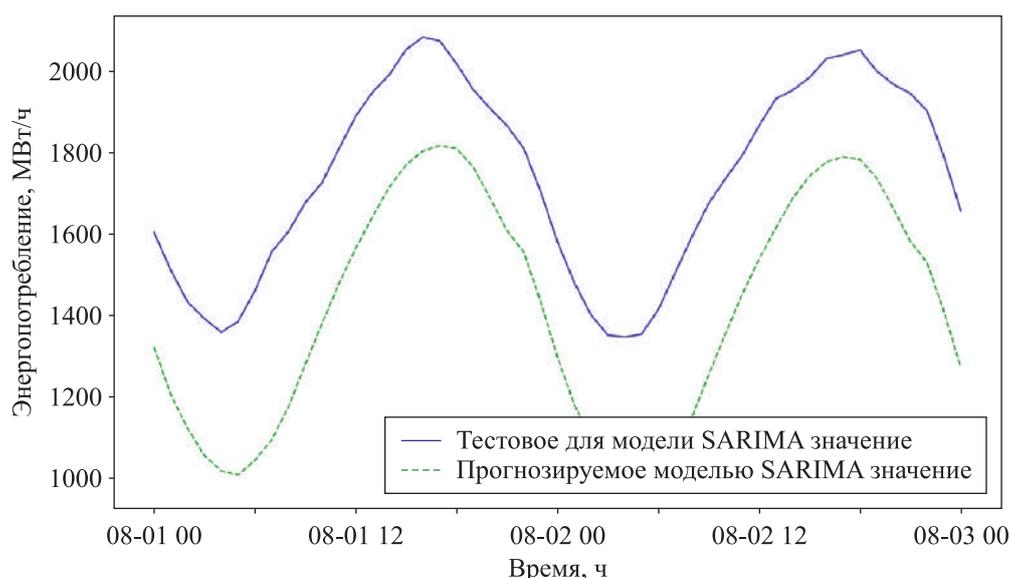


Рис. 9. Фрагмент результатов сравнения исходных значений, используемых для тестирования модели SARIMA, и значений, прогнозируемых с ее помощью

Результаты экспериментов показали, что если на обучаемых данных результаты прогноза с помощью модели SARIMA (1, 1, 3) (4, 1, 2, 24) отличаются в среднем на 1 %, то на тестовых данных — на 19 %.

4. Заключение

Описанный в работе метод позволяет определить состав входных переменных нейросетевой модели временного ряда и сократить трудоемкость ее построения за счет исключения полного или целенаправленного перебора вариантов состава входных переменных. Особенно предлагаемый подход эффективен для построения нейросетевых моделей для нестационарных временных рядов, когда в качестве входных переменных используются предыдущие значения с некоторым периодом. Входные переменные такой модели определяются в результате приведения нестационарного временного ряда к стационарному виду в результате сезонного и обычного взятия разностей, а также анализа АКФ, ЧАКФ. Построенные с помощью данного подхода прогнозные нейросетевые модели обладают достаточно высокой обобщающей способностью, позволяют с большей точностью аппроксимировать и прогнозировать значения временного ряда по сравнению с классическими моделями.

В перспективе, с целью ускорения процесса построения прогнозных нейросетевых моделей, целесообразно разработать метод автоматического определения параметров p , q , P_s , Q_s , используемых для определения состава входных переменных модели, на основе имитационного моделирования временных рядов, вычисления их автокорреляционных характеристик, построения и использования правил нечеткой логики.

Список литературы (References)

- Афанасьев В. Н., Юзбашев М. М. Анализ временных рядов и прогнозирование. — М.: Финансы и статистика, 2001. — 228 с.
Afanas'ev V. N., Yuzbashev M. M. Analiz vremennykh ryadov i prognozirovanie [Time series analysis and forecasting]. — Moscow: Finansy i statistika, 2001. — 228 p. (in Russian).

- Ахатов А. Р., Назаров Ф. М.* Разработка модели прогнозирования временных рядов нестационарных дискретных систем на основе нейронной сети // Проблемы информатики. — 2018. — № 3 (40). — С. 34–50.
Akhatov A. R., Nazarov F. M. Razrabotka modeli prognozirovaniya vremennykh ryadov nestatsionarnykh diskretnykh sistem na osnove neironnoi seti [Development of the model for prediction the time series of non-stationary discrete systems on the basis of neuron network] // Problems of Informatics. — 2018. — No. 3 (40). — P. 34–50 (in Russian).
- Бартењева О. В.* Параметры, влияющие на эффективность нейронной сети, созданной средствами Keras [Электронный ресурс]. URL: <http://www.100byte.ru/python/factors/factors.htm> (дата обращения: 09.01.2020).
Barten'ev O. V. Parametry, vliyayushchie na effektivnost' neironnoi seti, sozdannoi sredstvami Keras [Parameters affecting the efficiency of the neural network created by Keras] [Electronic resource] (in Russian). Available at: <http://www.100byte.ru/python/factors/factors.htm> (accessed: 09.01.2020).
- Бильгаева Л. П., Власов К. Г.* Исследование моделей нейросетевого прогнозирования в среде MATLAB // Приложение математики в экономических и технических исследованиях. — 2017. — № 1 (7). — С. 11–19.
Bil'gaeva L. P., Vlasov K. G. Issledovanie modelei neirosetevogo prognozirovaniya v srede MATLAB [The study of models of neural network forecasting in matlab] // Mathematics Application in Economic and Technical Research. — 2017. — No. 1 (7). — P. 11–19 (in Russian).
- Емалетдинова Л. Ю., Мухаметзянов З. И.* Методика нейросетевого прогнозирования на основе анализа временных рядов // Передовые инновационные разработки. Перспективы и опыт использования, проблемы внедрения в производство: сборник научных статей III Международной научной конференции, 30 апреля 2019 г. Часть 2. ООО «Конверт». — С. 16–17.
Emaletdinova L. Yu., Mukhametzyanov Z. I. Metodika neirosetevogo prognozirovaniya na osnove analiza vremennykh ryadov [Neural network forecasting technique based on time series analysis]. Sbornik nauchnykh statei III Mezhdunarodnoi nauchnoi konferentsii "Peredovye innovatsionnye razrabotki. Perspektivy i opyt ispol'zovaniya, problemy vnedreniya v proizvodstvo", 30 aprelya 2019 g. Part 2. ООО "Konvert". — P. 16–17 (in Russian).
- Захаров А. А., Оленников Е. А., Паюсова Т. И.* Интеллектуальный модуль анализа данных в информационных системах с помощью искусственных нейронных сетей // Вестник Тюменского государственного университета. Физико-математическое моделирование. Нефть, газ, энергетика. — 2015. — Т. 1, № 4. — С. 102–111.
Zakharov A. A., Olennikov E. A., Payusova T. I. Intellektual'nyi modul' analiza dannykh v informatsionnykh sistemakh s pomoshch'yu iskusstvennykh neironnykh setei [Intelligent module of data analysis for information systems based on artificial neural networks] // Tyumen State University Herald. Physical and Mathematical Modeling. Oil, Gas, Energy. — 2015. — Vol. 1, No. 4. — P. 102–111 (in Russian).
- Зуева В. Н., Трухан Д. А., Карлов Д. Н.* Нейросетевой модуль прогнозирования потребления электроэнергии // Политематический сетевой электронный научный журнал Кубанского государственного аграрного университета. — 2017. — № 132. — С. 1322–1331. — URL: <http://ej.kubagro.ru/2017/08/pdf/107.pdf> (дата обращения: 02.01.2020).
Zueva V. N., Trukhan D. A., Karlov D. N. Neurosetevoi modul' prognozirovaniya potrebleniya elektroenergii [Neural network prediction module for electricity consumption] // Polythematic Online Scientific Journal of Kuban State Agrarian University. — 2017. — No. 132. — P. 1322–1331 (in Russian). — Available at: <http://ej.kubagro.ru/2017/08/pdf/107.pdf> (accessed: 02.01.2020).
- Катасёв А. С.* Нейронечеткая модель формирования нечетких правил для оценки состояния объектов в условиях неопределенности // Компьютерные исследования и моделирование. — 2019. — Т. 11, № 3. — С. 477–492.
Katasev A. S. Neironechetkaya model' formirovaniya nechetkikh pravil dlya otsenki sostoyaniya ob'ektov v usloviyakh neopredelennosti [Neuro-fuzzy model of fuzzy rules formation for objects state evaluation in conditions of uncertainty] // Computer Research and Modeling. — 2019. — Vol. 11, No. 3. — P. 477–492 (in Russian).
- Киселев А. В., Петрова Т. В., Дегтярев С. В., Рыбочкин А. Ф., Филист С. А., Шаталова О. В., Мишустин В. Н.* Нейросетевые модели с виртуальными потоками для классификации и прогнозирования функционального состояния сложных систем // Известия Юго-Западного государственного университета. — 2018. — № 4 (79). — С. 123–134.
Kiselev A. V., Petrova T. V., Degtyarev S. V., Rybochkin A. F., Filist S. A., Shatalova O. V., Mishustin V. N. Neurosetevye modeli s virtual'nymi potokami dlya klassifikatsii i pronozirovaniya funktsional'nogo sostoyaniya slozhnykh sistem [Hybrid deciding modules with virtual streams for classification and prediction of functional state of complex systems] // Proceedings of The Southwest State University. — 2018. — No. 4 (79). — P. 123–134 (in Russian).

- Колмаков И. Б., Кольцов А. В., Доможаков М. В.* Сравнительный анализ систем регрессионного и нейросетевого краткосрочного прогнозирования // *Инноватика и экспертиза: научные труды.* — 2016. — № 3 (18). — С. 118–137.
Kolmakov I. B., Kol'tsov A. V., Domozhakov M. V. Sravnitel'nyi analiz sistem regressionnogo i neirosetevogo kratkosrochnogo prognozirovaniya [Comparative analysis of regression and neural network short-term forecasting systems] // *Innovatics and Expert Examination: scientific proceedings.* — 2016. — No. 3 (18). — P. 118–137 (in Russian).
- Проталинский О. М., Щербатов И. А., Ханова А. А., Проталинский И. О.* Адаптивная система прогнозирования надежности технологического оборудования объектов энергетики // *Информатика и системы управления.* — 2019. — № 1 (59). — С. 93–105.
Protalinskii O. M., Shcherbatov I. A., Khanova A. A., Protalinskii I. O. Adaptivnaya sistema prognozirovaniya nadezhnosti tekhnologicheskogo oborudovaniya obektov energetiki [Adaptive system for predicting the reliability of technological equipment of energy facilities] // *Information Science and Control Systems.* — 2019. — No. 1 (59). — P. 93–105 (in Russian).
- Селиверстова А. В.* Сравнительный анализ моделей и методов прогнозирования // *Современные научные исследования и инновации.* — 2016. — № 11 (67). — С. 241–248.
Seliverstova A. V. Sravnitel'nyi analiz modelei i metodov prognozirovaniya [Comparative analysis of models and methods of forecasting] // *Modern Scientific Researches and Innovations.* — 2016. — No. 11 (67). — P. 241–248 (in Russian).
- Ткалич С. А., Бурковский В. Л., Таратынов О. Ю.* Концепция безаварийного управления на основе моделей прогнозирования состояний потенциально опасных технологических процессов // *Вестник Воронежского государственного технического университета.* — 2016. — Т. 12, № 6. — С. 79–86.
Tkalich S. A., Burkovskii V. L., Taratynov O. Yu. Kontseptsiya bezavariinogo upravleniya na osnove modelei prognozirovaniya sostoyanii potentsial'no opasnykh tekhnologicheskikh protsessov [The concept of accident-free control on the basis of forecasting models of statuses potentially dangerous technological processes] // *Bulletin of Voronezh State Technical University.* — 2016. — Vol. 12, No. 6. — P. 79–86 (in Russian).
- Трегуб А. В., Трегуб И. В.* Методика построения модели ARIMA для прогнозирования динамики временных рядов // *Лесной вестник.* — 2011. — № 5 (81). — С. 179–183.
Tregub A. V., Tregub I. V. Metodika postroeniya modeli ARIMA dlya prognozirovaniya dinamiki vremennykh ryadov [The procedure of construction the ARIMA model for forecasting the time series dynamics] // *Forestry Bulletin.* — 2011. — No. 5 (81). — P. 179–183 (in Russian).
- Шепелев И. Е., Надтока И. И., Вялкова С. А., Губский С. О.* Сравнительный анализ итерационного и прямого нейросетевого краткосрочного прогнозирования электропотребления крупного города // *Нейрокомпьютеры: разработка, применение.* — 2016. — № 3. — С. 21–30.
Shepelev I. E., Nadtoka I. I., Vyalkova S. A., Gubskii S. O. Sravnitel'nyi analiz iteratsionnogo i pryamogo neirosetevogo kratkosrochnogo pronozirovaniya elektropotrebleniya krupnogo goroda [Comparative study of iterative and direct neural network short term electricity load forecasting of a city] // *Journal Neurocomputers.* — 2016. — No. 3. — P. 21–30 (in Russian).
- Шолле Ф.* Глубокое обучение на Python. — СПб.: Питер, 2018. — 400 с.
Chollet F. Glubokoe obuchenie na Python [Deep learning with Python]. — St. Petersburg: Piter, 2018. — 400 p. (in Russian).
- Шолтанюк С. В.* Сравнительный анализ нейросетевой и регрессионных моделей прогнозирования временных рядов // *Цифровая трансформация.* — 2019. — № 2. — С. 60–68.
Sholtanyuk S. V. Sravnitel'nyi analiz neirosetevoi i regressionnykh modelei prognozirovaniya vremennykh ryadov [Comparative analysis of neural networking and regression models for time series forecasting] // *Digital Transformation.* — 2019. — No. 2. — P. 60–68 (in Russian).
- Якупов Д. Т., Рожко О. Н.* Перспективы применения искусственных нейронных сетей для прогнозирования объемов грузоперевозок в транспортных системах // *Статистика и экономика.* — 2017. — № 5. — С. 49–60.
Yakupov D. T., Rozhko O. N. Perspektivy primeneniya iskusstvennykh neironnykh setei dlya prognozirovaniya ob'emov gruzoperevozok v transportnykh sistemakh [Prospects of application of artificial neural networks for forecasting of cargo transportation volume in transport systems] // *Statistics and economics.* — 2017. — No. 5. — P. 49–60 (in Russian).
- Bandara K., Bergmeir C., Smyl S.* Forecasting across time series databases using recurrent neural networks on groups of similar series: A clustering approach // *Expert Systems with Applications.* — 2020. — Vol. 140. — Article 112896.

- Jiang P., Yang H., Heng J.* A hybrid forecasting system based on fuzzy time series and multi-objective optimization for wind speed forecasting // *Applied Energy*. — 2019. — Vol. 235. — P. 786–801.
- Jinu L.* A neural network method for nonlinear time series analysis // *Journal of Time Series Econometrics*. — 2019. — Vol. 11 (1). — P. 1–18.
- Kumar D. N., Raju K. S., Sathish T.* River flow forecasting using recurrent neural networks // *Water Resources Management*. — 2004. — Vol. 18, No. 2. — P. 143–161.
- Nguyen L., Novak V.* Forecasting seasonal time series based on fuzzy techniques // *Fuzzy Sets and Systems*. — 2019. — Vol. 361. — P. 114–129.
- Singhal D., Swarup K. S.* Electricity price forecasting using artificial neural networks // *International Journal of Electrical Power and Energy Systems*. — 2011. — Vol. 33, No. 3. — P. 550–555.
- Tealab A., Hefny H., Badr A.* Forecasting of nonlinear time series using artificial neural network // *Future Computing and Informatics Journal*. — 2017. — 10 p. — DOI: 10.1016/j.fcij.2017.06.001
- Zulifqar A., Hussain I., Faisal M., Nazir H. M., Hussain T., Shad M. Y., Shoukry A. M., Gani S. H.* Forecasting drought using multilayer perceptron artificial neural network model // *Advances in Meteorology*. — 2017. — Vol. 2017, No. 2. — 9 p. — DOI: 10.1155/2017/5681308