

Прогнозирование временных рядов. Прогнозирование платежей физических клиентов энергосбытовой компании

А. В. Ерошкин¹, М. А. Потапова^{2✉}, А. Е. Лончина¹

¹ Санкт-Петербургский государственный электротехнический университет «ЛЭТИ» им. В. И. Ульянова (Ленина), Санкт-Петербург, Россия

² Санкт-Петербургский государственный политехнический университет, Санкт-Петербург, Россия

✉ potapova.ma@mail.ru

Аннотация. Решается задача прогнозирования временного ряда, описывающего платежи за электроэнергию физических клиентов энергосбытовой компании. Временной ряд сложен и нестационарен, в нем выражены сезонность и тренд, что указывает на невозможность выбора простых методов прогнозирования – таких, как экстраполяция или метод наивного прогнозирования. В связи с этим для решения задачи были выбраны различные методы машинного обучения и нейронные сети, которые способны находить сложные зависимости в данных и учиться их прогнозировать. Для решения задачи были выбраны несколько регрессионных моделей машинного обучения, часто используемых в решении задач прогнозирования временных рядов: XGBoost, SVM, LSSVM, LGBM и GradientBoosting, а также нейронные сети – LSTM, RNN, CNN и т. д. Лучший результат был получен при помощи машины опорных векторов регрессии (SVR). Реализация этой модели была интегрирована в веб-приложение для прогнозирования временных рядов. Рассматривается также алгоритм определения стационарности ряда при помощи теста Дики–Фуллера и приведения временного ряда к стационарному при помощи дифференцирования временного ряда. Кроме этого, в статье рассматривается проблема прогнозирования выбросов (пиков). Большинство методов прогнозирования не решают проблему прогнозирования пиков, поскольку они считают их статистическими выбросами. В статье эта проблема решается выделением пиков в отдельный временной ряд и прогнозированием их отдельно от основного ряда с дальнейшим соединением двух прогнозов.

Ключевые слова: временные ряды, прогнозирование, машина опорных векторов, сезонность, декомпозиция, регрессия, LSTM, прогнозирование пиков (выбросов)

Для цитирования: Ерошкин А. В., Потапова М. А., Лончина А. Е. Прогнозирование временных рядов. Прогнозирование платежей физических клиентов энергосбытовой компании // Изв. СПбГЭТУ «ЛЭТИ». 2023. Т. 16, № 10. С. 60–69. doi: 10.32603/2071-8985-2023-16-10-60-69.

Конфликт интересов. Авторы заявляют об отсутствии конфликта интересов.

Original article

Time Series Forecasting. Forecasting Payments of Physical Individual Customers' Payments of an Power Supplyenergy Sales Company

A. V. Eroshin¹, M. A. Potapova^{2✉}, A. E. Lonchina¹

¹ Saint Petersburg Electrotechnical University, Saint Petersburg, Russia

² Peter the Great Saint Petersburg Polytechnic University, Saint Petersburg, Russia

✉ potapova.ma@mail.ru

Abstract. This article solves the problem of forecasting a time series which describes electricity payments of individual for electricity by physical customers of a power supply energy marketing company. The complex and non-stationary nature of the time series, along with it is complex and non-stationary, seasonality and trend are expressed in it, which limits indicates that it is impossible to choose using simpler forecasting methods, such as

extrapolation or naive forecasting method. Therefore in this regard, various machine learning methods and neural networks were chosen to solve the problem, various machine learning methods and neural networks were chosen which can find complex dependencies in data and learn to predict them. To solve the problem, several regression models of machine learning were chosen, often used in solving time-series forecasting problems, for example, XGBoost, SVM, LSSVM, LGBM, and Gradient Boosting, as well as neural networks, such as LSTM, RNN, and CNN. The best result was obtained using a regression support vector regression machine (SVR) machine. This implementation of this model has been integrated into a web application for time-series forecasting. The article also discusses an algorithm for determining the stationarity of a series using the Dickey–Fuller test and bringing a time series to a stationary series one by differentiating the former one a time series. In addition, the article addresses the problem of forecasting emissions (peaks). Most forecasting methods do not solve the problem of predicting peaks because they consider them statistical outliers. In the article, this problem is solved by separating the peaks into a separate time series and predicting them separately from the main series with further connection of the two forecasts.

Keywords: time-series, forecasting, support vector machine, seasonality, decomposition, regression, LSTM, peaks forecasting

For citation: Eroshlin A. V., Potapova M. A., Lonchina A. E. Time Series Forecasting. Forecasting Payments of Physical Individual Customers' Payments of an Power Supplyenergy Sales Company // LETI Transactions on Electrical Engineering & Computer Science. 2023. Vol. 16, no. 10. P. 60–69. doi: 10.32603/2071-8985-2023-16-10-60-69.

Conflict of interest. The authors declare no conflicts of interest.

Введение. Объем потребления электроэнергии увеличивается из года в год. Люди приобретают и используют все большее количество бытовой техники, гаджетов и других энергопотребляющих приборов. Также потребление электроэнергии увеличивается за счет расширения числа клиентов энергосбытовых компаний.

В связи с этим аналитики вынуждены работать с постоянно растущим объемом данных, из-за чего становится сложнее планировать финансово-экономический бюджет внутри энергосбытовой компании. Эта проблема служит поводом для создания инструмента поддержки принятия решения аналитиков энергосбытовой компании. Инструмент позволит прогнозировать различные финансовые показатели энергосбытовой компании.

Один из таких показателей – платежи физических клиентов энергосбытовой компании. Прогнозирование подобных данных позволяет компании рационально распределять полученную прибыль. В статье рассматривается прогнозирование этого показателя, а также решение проблемы с прогнозированием пиковых значений.

Постановка задачи. Перед прогнозированием необходимо проанализировать временной ряд и выделить в нем закономерности: когда большинство людей платят за электроэнергию, почему они платят в эти дни, есть ли какие-либо сезонные зависимости в наборе данных и другие воз-

можные закономерности между данными и внешними факторами.

Для анализа были использованы данные, полученные от энергосбытовой компании за 10 лет (с 01.01.2012 по 31.03.2022). Данные представлены в виде таблицы, каждая строка состоит из даты платежа и общей суммы платежей клиентов за этот день. Данные можно визуализировать так, как это показано на рис. 1 и 2. Для удобства данные были разделены на 2 части (период с 01.01.2012 по 31.12.2016 и период с 01.01.2017 по 31.03.2022).

На рис. 1, 2 заметны «пиковые» даты платежей, в которые общие суммы платежей физических клиентов гораздо больше, чем в другие дни, а также выражено их сезонное повторение. Поскольку пиковые значения играют важную роль в решении данной задачи, так как в такие даты компания получает самую большую прибыль, необходимо разработать алгоритм прогнозирования пиковых (выбросов) значений.

Было разработано веб-приложение «Sigma Prediction» с микросервисной архитектурой, которое позволяет работать с данными и прогнозировать их. Система состоит из четырех основных компонентов:

1. Клиент приложения. Использованные технологии: JavaScript, фреймворк React.

2. Сервер приложения. Использованные технологии Java, фреймворк Spring Boot.




Рис. 1. Визуализация данных с 01.01.2012 по 31.12.2016
Fig. 1. Data visualization from 01.01.2012 to 31.12.2016




Рис. 2. Визуализация данных с 01.01.2017 по 31.03.2022
Fig. 2. Data visualization from 01.01.2017 to 31.03.2022

3. База данных. Используемые технологии: PostgreSQL.

4. Сервис прогнозирования. Используемые технологии: Python, Flask.

Приложение было развернуто на серверах компании с использованием контейнеризации Docker и Docker Compose. Представленные в статье графики реализованы с использованием инструмента Chart.js.

Методология исследования. Далее приведено описание выбранных моделей прогнозирования.

В основе регрессии опорных векторов (SVR) лежит поиск гиперплоскости, при которой ошибка в многомерном пространстве будет минимальной [1]. Итак, если прогнозируемое значение попадает в область гиперплоскости, то потери равны нулю. В противном случае возникает разница между прогнозируемыми и фактическими значениями. Цель алгоритма – минимизировать ошибку посредством определения функции, которая размещает больше начальных точек внутри трубки [2]:

$$y = f(x) = \omega^T \varphi(x) + b,$$

где ω – вектор нормали гиперплоскости (вектор весов многомерного пространства); b – член смещения; $x \in R^n$, $y \in R^n$ и $\varphi(\cdot): R^n \rightarrow R^{nh}$ – отображение на пространство большей размерности.

Результирующее многомерное внутреннее произведение заменяется функцией ядра, называемой гауссовым ядром [2]:

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}},$$

где σ – настраиваемый параметр; x_i, x_j – векторы для точек с индексами i и j соответственно.

LSSVM – это версия алгоритма SVM [2], [3]. LSSVM использует организованную функцию наименьших квадратов, приводящую к линейной системе уравнений. Следовательно, задача регрессии может быть решена с использованием системы линейных уравнений, а не квадратичного программирования, как в SVM. Метод наименьших квадратов опорных векторов регрессии (LSSVR) предназначен для аппроксимации неизвестной функции с использованием заданного ряда обучающих данных. В результате задача оптимизации сводится к решению функции регрессии, функция ядра имеет тот же вид, что и SVR [2]:

$$f(x) = \sum_i^n \alpha_i K(x_i, x_j) + b,$$

где α_i и b – решения линейной системы.

Gradient Boosting – это алгоритм машинного обучения для решения задач классификации и регрессии. Он строит прогноз как совокупность слабых прогностических моделей, которые обычно представляют собой деревья решений. В конце концов алгоритм выбирает одну, но самую эффективную. Общая идея алгоритма заключается в последовательном применении предиктора таким образом, чтобы каждая последующая модель сводила ошибку предыдущей к минимуму.

XGBoost – это алгоритм коллективного обучения, основанный на итерациях градиентного спуска. XGBoost использует дерево решений в качестве основного обучающего элемента для интеграции. Алгоритм заключается в постоянном добавлении новых деревьев, каждое из которых вычисляет пороговые признаки с наилучшим эффектом ветвления, и завершает построение разделения. Главная задача этого алгоритма – минимизация функции оптимизации [4]:

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)}) + f_t(x_i) + \Omega(f_t),$$

где l – функция потерь; y_i – значение i -го элемента обучающей выборки; $\hat{y}_i^{(t-1)}$ – сумма предсказаний первых t деревьев для i -го элемента; x_i – набор признаков i -го элемента обучающей выборки; f_t – функция (здесь – дерево), которую нужно обучить на шаге t ; $f_t(x_i)$ – предсказание на i -м элементе обучающей выборки; $\Omega(f_t)$ – регуляризация функции f .

LightGBM – это фреймворк для улучшения градиента, который использует древовидные алгоритмы обучения [5]. Он оптимизирует алгоритм XGBoost для обеспечения эффективной обработки крупномасштабных данных. LightGBM реализует оптимизированный алгоритм обучения дерева решений на основе гистограмм, который дает большие преимущества в плане как эффективности, так и потребления памяти. Это ускоряет обучение и сокращает использование памяти.

Рекуррентные нейронные сети (RNN) – это класс нейронных сетей, которые подходят для моделирования последовательных данных – временных рядов или естественного языка [6]. При прогнозировании временных рядов часто используются нейронные сети прямого распространения, но такие модели применимы для задач, в которых степень зашумленности ряда минимальна.

Но в реальных задачах таких данных практически не существует, из-за чего решать задачу прогнозирования становится сложнее. Использование совокупности сетей прямого распределения помогает снизить уровень шума.

К недостаткам простых RNN относится, например, «исчезающий» градиент. Это явление, когда градиенты, используемые для вычисления обновления веса, могут быть очень близки к нулю, что не позволяет сети перераспределять и изменять веса узлов. Чем глубже сеть, тем более выражена эта проблема. Для ее решения применяется модель нейронной сети LSTM [7]. Блоки LSTM содержат три «вентиля», которые используются для управления потоком информации на входах и выходах памяти этих блоков. Эти клапаны реализованы как логистическая функция для вычисления значения в диапазоне [0; 1]. Умножение на это значение используется для частичного разрешения или запрета потока информации в память и из нее.

Сверточные нейронные сети (CNN) – это основной подход для работы с данными, имеющими пространственную структуру [8]. Они успешно применяются для извлечения пространственных свойств объекта.

Для анализа ряда используются разложение на составляющие, тест Дики–Фуллера и построение графиков автокорреляции и частичной корреляции временного ряда [9]. Тест Дики–Фуллера – это методика, которая используется в прикладной статистике и эконометрике для анализа временных рядов для проверки на стационарность. Служит одним из тестов на единичные корни. Временной ряд имеет единичный корень, или порядок интеграции 1, если его первые разности образуют стационарный ряд.

Используемые инструменты содержат в себе модуль для реализации этого теста. В ходе него вычисляются вероятность того, что нулевая гипотеза о том, что ряд нестационарный, не будет отклонена; критическое значение для ряда; критические значения самого теста.

Если полученное критическое значение для ряда больше, чем критическое значение самого теста Дики–Фуллера, то такой ряд считается нестационарным. Также если полученное значение вероятности больше заданного значения, то ряд также нестационарный.

Для решения проблемы прогнозирования пиков был использован следующий алгоритм:

1. В основном ряду выделяется 5 % от наибольших сумм в каждом месяце временного ряда.
2. Применяется линейная интерполяция между этими датами.
3. При помощи выбранных моделей прогнозирования прогнозируются пики.
4. Спрогнозированные пиковые значения подменяются в прогнозе основного ряда.

Обсуждение результатов. Для исследуемого ряда проводился эксперимент для критического значения вероятности об отклонении нулевой гипотезы в 5 %. Ряд оказался нестационарным, полученная вероятность для ряда – 16 %, что больше, чем 5 %. Кроме того, полученные графики автокорреляции и частичной корреляции показывают, что ряд нестационарный и имеет в себе ярко выраженную сезонность. Графики изображены на рис. 3 и 4.

Приведение ряда к стационарному дифференцированием ряда 100 раз не привел к ожидаемым результатам и ряд остался нестационарным. Графики автокорреляции и частичной корреляции ряда приведены на рис. 5 и 6 соответственно. Дальнейшее увеличение количества дифференцирования не привело к стационарности ряда.

Временной ряд был разложен на составляющие. На рис. 7 показана сезонная составляющая данных. Прослеживается еженедельная закономерность, поскольку большинство людей платят за электроэнергию начиная с понедельника, а в выходные по большей части не оплачивают счета. Другая причина может заключаться в том, что люди получают квитанцию в понедельник, после выходных, что также влияет на сезонную составляющую.




Рис. 3. График функции автокорреляции временного ряда
Fig. 3. Graph of the autocorrelation function of a time series




Рис. 4. График функции частичной корреляции временного ряда
Fig. 4. Graph of the partial correlation function of a time series

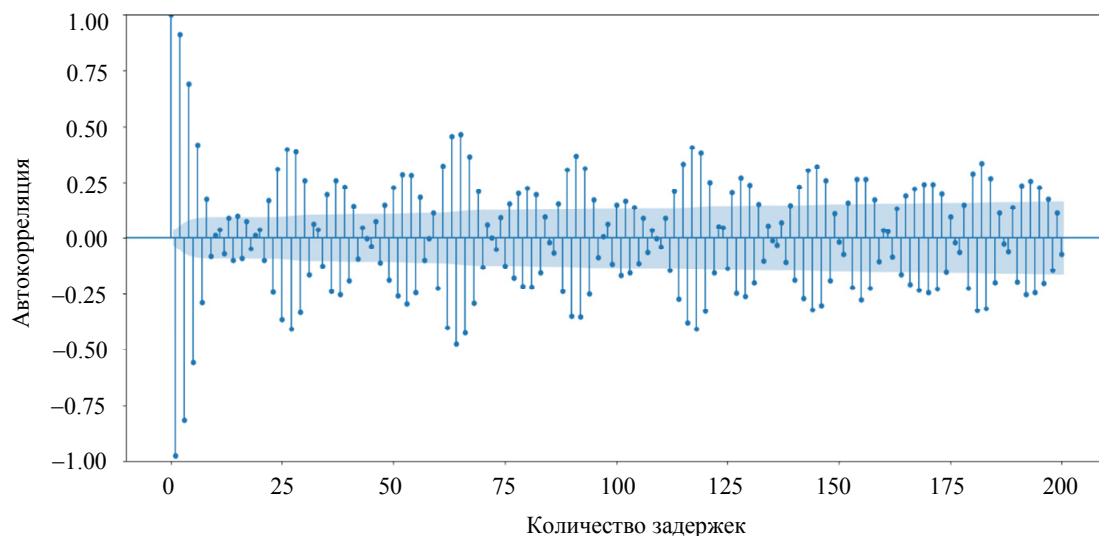


Рис. 5. График функции автокорреляции продифференцированного временного ряда
Fig. 5. Graph of the autocorrelation function of a differentiated time series

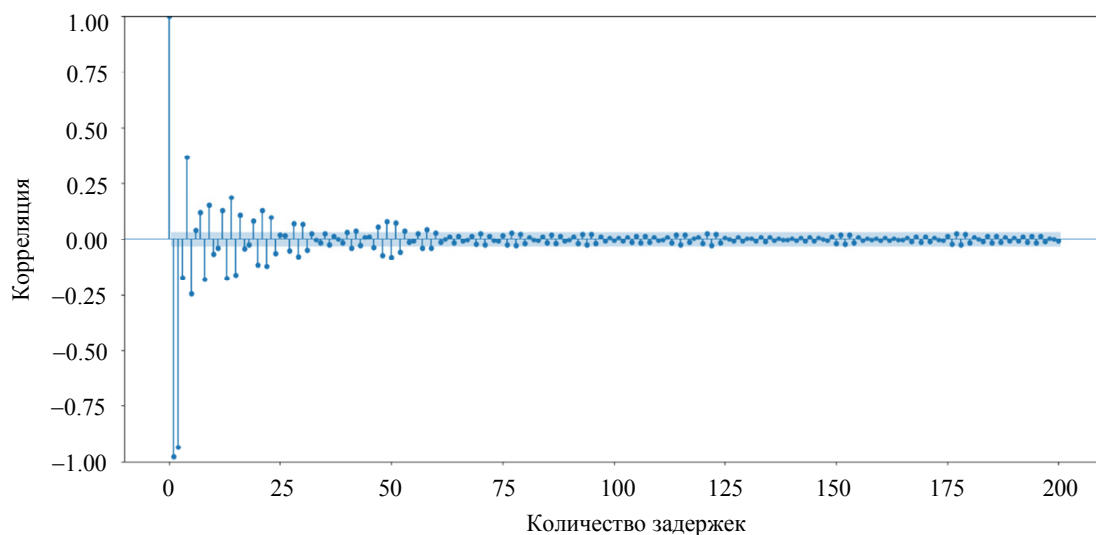


Рис. 6. График функций частичной корреляции продифференцированного временного ряда
Fig. 6. Graph of partial correlation functions of a differentiated time series

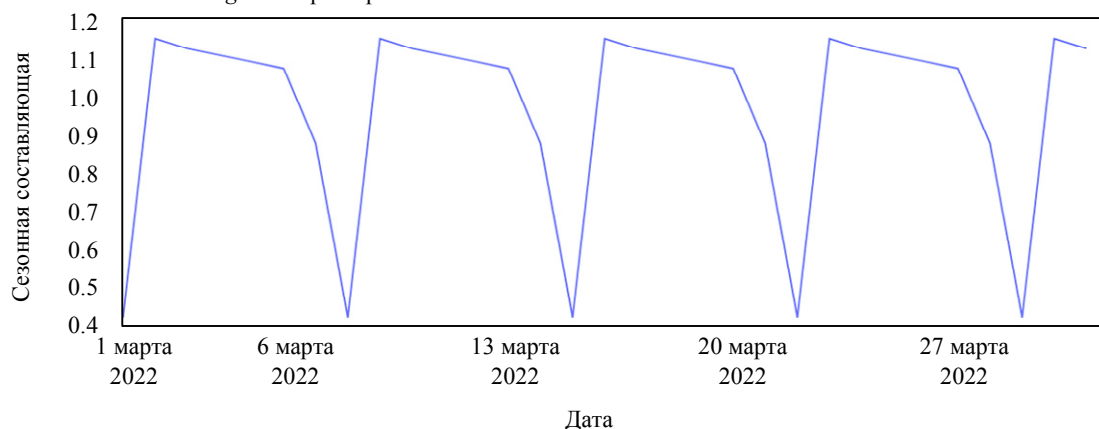


Рис. 7. Сезонная составляющая ряда
Fig. 7. Seasonal component of the series

Доказательства этой закономерности можно увидеть на рис. 8. На представленной гистограмме описана статистика о самых платежеспособ-

ных днях каждой недели. И, как показано в сезонной составляющей, понедельник – самый вы-




Рис. 8. Гистограмма о самых платежеспособных днях недели
Fig. 8. Histogram of the most payment days of the week

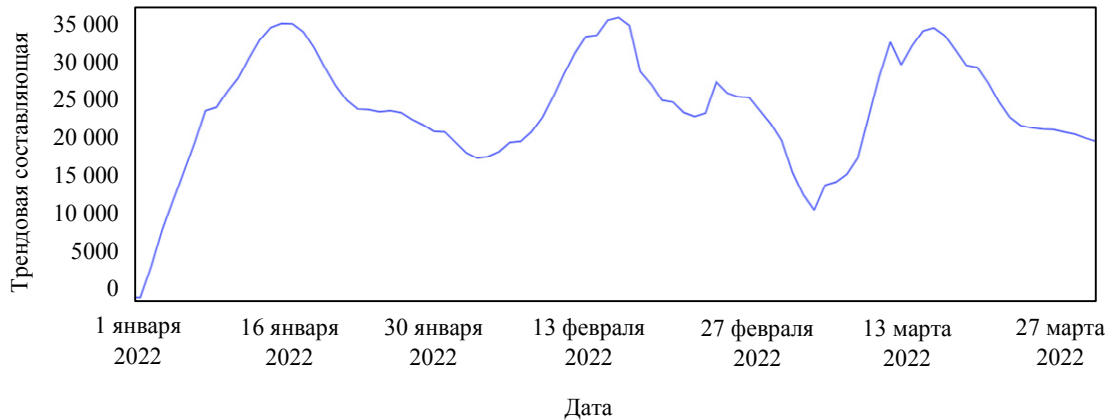


Рис. 9. Трендовая составляющая ряда
Fig. 9. Trend part of a time-series

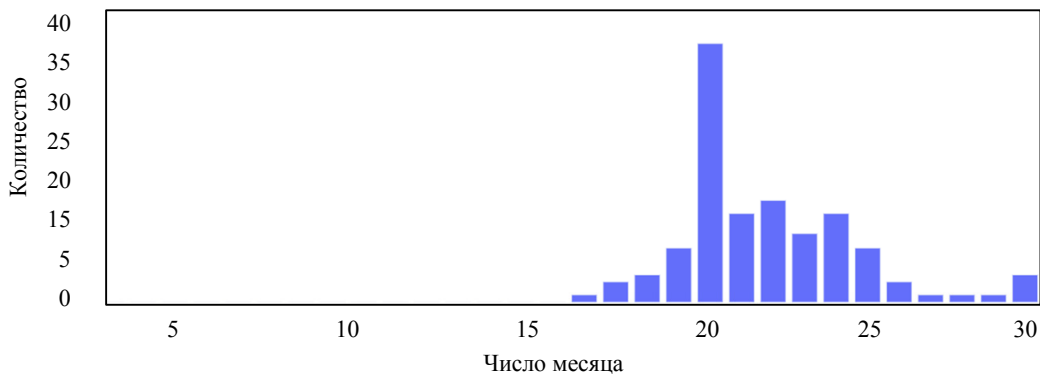


Рис. 10. Гистограмма о самых платежеспособных днях каждого месяца
Fig. 10. Histogram of the most payment days of every month

сокооплачиваемый рабочий день, а выходные – последние в этом списке.

На рис. 9 представлен тренд временного ряда. По нему можно заметить, что рост графика наблюдается 20-го числа каждого месяца. Эта закономерность может быть связана с двумя причинами. Во-первых, во многих российских компаниях люди получают зарплату во второй декаде каждого месяца. Во-вторых, клиенты энергосбытовых компаний также получают счета на оплату за электроэнергию в этот период.

Ту же закономерность можно заметить на гистограмме (рис. 10), описывающей статистику по

самым платежеспособным дням за каждый месяц. 20-е число наиболее вероятно для совпадения с «пиковым» значением.

Для прогнозирования использовался метод скользящего окна. При этом методе построение каждого нового прогноза происходит на основе N предыдущих значений ряда, где N – размер окна. Например, при размере окна в 30 значений каждое новое значение прогнозируется на основе 30 предыдущих. Модели показали наилучшие результаты при скользящем окне в 180 дней, поэтому точность сравнивается именно для этого размера окна.

Результаты прогнозирования приведены в таблице. Для их оценки использовалась средняя абсолютная процентная ошибка (MAPE).

Результаты прогнозирования
 Forecasting results

Модель	MAPE, %
Gradient Boosting Regressor	14.63
XGB Regressor	14.09
LGBM Regressor	14.03
LSSVR	13.42
SVR	12.60
RNN	18.66
LSTM	17.53
CNN	16.54

Исходя из полученных результатов, для системы прогнозирования была выбрана модель SVR, поскольку она обладает наибольшей точностью. Результат прогнозирования представлен на рис. 11.

После объединения основного прогноза модели SVR и предсказанных пиков ошибка модели составила 12.2 %. Результат показан на рис. 12.

Заключение. В наборе данных явно заметны сезонные закономерности, а также корреляция между тем, что люди платят больше всего в определенные дни, и различными событиями в их жизни – например, днями, когда люди получают зарплату, счета за электричество, нерабочими днями и другими подобными событиями. Для прогнози-

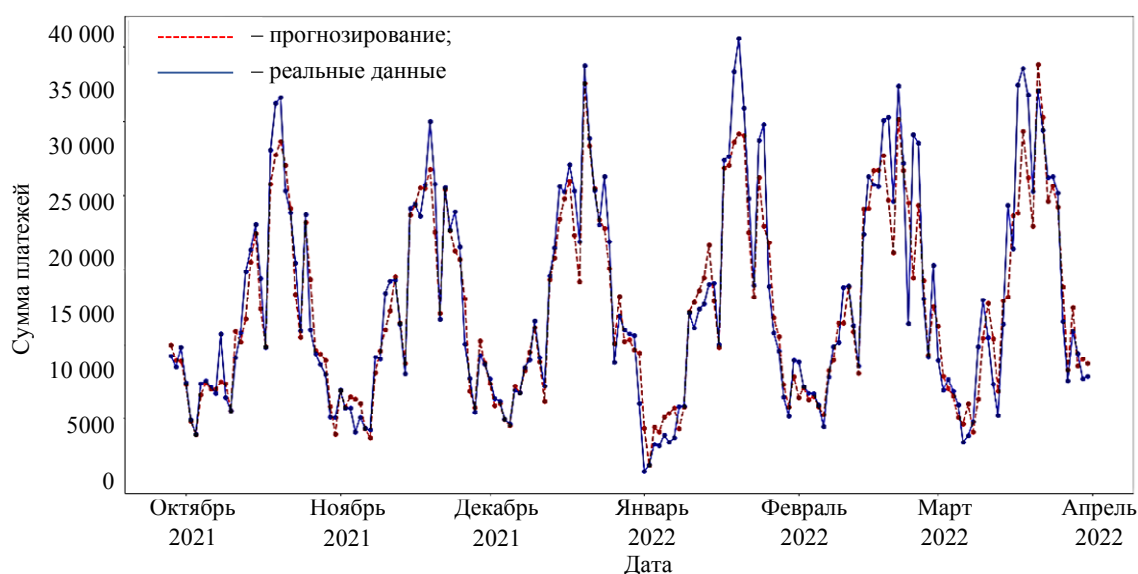


Рис. 11. Результат прогнозирования временного ряда на 6 месяцев вперед с использованием модели SVR
 Fig. 11. The result of forecasting a time series for 6 months ahead using the SVR model

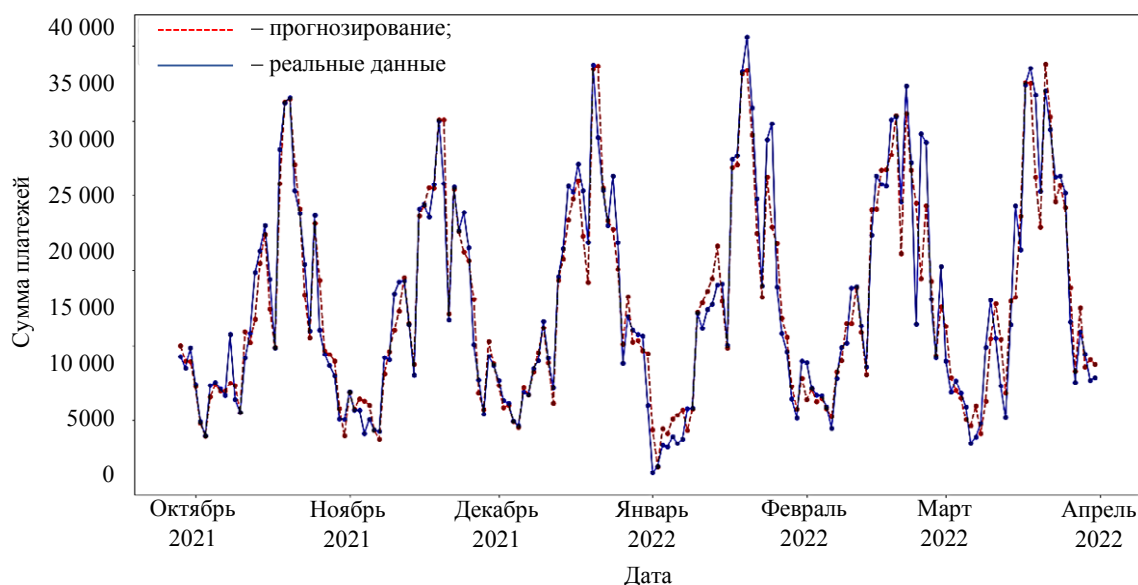


Рис. 12. Результат прогнозирования временного ряда на 6 месяцев вперед с использованием комбинации прогнозов основного ряда и пиков
 Fig. 12. The result of forecasting a time series for 6 months ahead using a combination of forecasts of the main series and peaks

рования платежей физических клиентов были использованы различные методы прогнозирования временных рядов на основе данных, предоставленных энергосбытовой компанией, описывающих объем платежей физических клиентов. Были выбраны 8 различных методов прогнозирования для анализа и получены результаты прогнозирования на 6 месяцев вперед. Лучший результат был получен при помощи регрессионного метода опорных векторов (SVR) с ошибкой 12.6 %. Проблема с пиковыми значениями была решена выделением пиков в новый набор данных, даль-

нейшим их прогнозированием, а затем объединением исходного предсказания и спрогнозированных пиковых значений. Полученная ошибка после объединения составила – 12.2 %.

В будущем планируется использовать другие подходы к прогнозированию, поскольку использование только одной модели прогнозирования не приводит к достаточному результату. Вероятно, если применять ансамбли моделей прогнозирования со всеми преимуществами каждой из них, можно находить нужные закономерности в наборе данных и предсказывать их.

Список литературы

1. Short-term hybrid forecasting model of ice storage air-conditioning based on improved SVR / R. Cheng, J. Yu, M. Zhang, Ch. Feng, W. Zhang // SID Int. J. of Building Engin. 2022. Vol. 50. P. 104194. doi: 10.1016/j.jobe.2022.104194.
2. Kaytez F. A hybrid approach based on autoregressive integrated moving average and least-square support vector machine for long-term forecasting of net electricity consumption // SID Int. Energy. 2020. Vol. 197. P. 117200.
3. Qu J., Zuo M. J. An LSSVR-based algorithm for online system condition prognostics // Expert Systems with Appl. 2012. Vol. 39, no. 5. P. 6089–6102.
4. Machine learning models for predicting the residual value of heavy construction equipment: An evaluation of modified decision tree, LightGBM, and XGBoost regression / A. Shehadeh, O. Alshboul, R. E. Al Mamlook, O. Hamedat // Automation in Construction. 2021. Vol. 129. P. 103827.
5. PM2.5 extended-range forecast based on MJO and S2S using LightGBM / Zh. Yu, J. Ma, Yu. Qu, L. Pan, Sh. Wan // Sci. of the Total Environment. 2023. Vol. 880. P. 163358.
6. Temporal Convolutional Networks with RNN approach for chaotic time series prediction / H. V. Dudukcu, M. Taskiran, Z. G. C. Taskiran, T. Yildirim // Appl. Soft Computing. 2023. Vol. 133. P. 109945.
7. Gajamannage K., Park Yo., Jayathilake D. I. Real-time forecasting of time series in financial markets using sequentially trained dual-LSTMs // Expert Systems with Appl. 2023. Vol. 223. P. 119879.
8. Dong X., Guo M., Wang Shi. Active control method for the sinking of open caissons: A data-driven approach based on CNN and time series prediction // Ocean Engin. 2022. Vol. 257. P. 111683.
9. Verma Tu. Complete guide to Dickey-Fuller test // Time-Series Analysis. URL: <https://analyticsindiamag.com/complete-guide-to-dickey-fuller-test-in-time-series-analysis> (дата обращения 12.04.2023).

Информация об авторах

Ерошкин Александр Владимирович – старший преподаватель кафедры автоматике и процессов управления СПбГЭТУ «ЛЭТИ».
E-mail: eroshkin.a.spb@gmail.com

Потапова Мария Алексеевна – магистрант высшей школы программной инженерии Санкт-Петербургского государственного политехнического университета им. Петра Великого.
E-mail: potapova.ma@mail.ru

Лончина Александра Евгеньевна – ассистент кафедры автоматике и процессов управления СПбГЭТУ «ЛЭТИ».
E-mail: sashalonchina@gmail.com

References

1. Short-term hybrid forecasting model of ice storage air-conditioning based on improved SVR / R. Cheng, J. Yu, M. Zhang, Ch. Feng, W. Zhang // SID Int. J. of Building Engin. 2022. Vol. 50. P. 104194. doi: 10.1016/j.jobe.2022.104194.
2. Kaytez F. A hybrid approach based on autoregressive integrated moving average and least-square support vector machine for long-term forecasting of net electricity consumption // SID Int. Energy. 2020. Vol. 197. P. 117200.

3. Qu J., Zuo M. J. An LSSVR-based algorithm for online system condition prognostics // Expert Systems with Appl. 2012. Vol. 39, no. 5. P. 6089–6102.

4. Machine learning models for predicting the residual value of heavy construction equipment: An evaluation of modified decision tree, LightGBM, and XGBoost regression / A. Shehadeh, O. Alshboul, R. E. Al Mamlook, O. Hamedat // Automation in Construction. 2021. Vol. 129. P. 103827.

5. PM2.5 extended-range forecast based on MJO and S2S using LightGBM / Zh. Yu, J. Ma, Yu. Qu, L. Pan, Sh. Wan // Sci. of the Total Environment. 2023. Vol. 880. P. 163358.

6. Temporal Convolutional Networks with RNN approach for chaotic time series prediction / H. V. Du-

dukcu, M. Taskiran, Z. G. C. Taskiran, T. Yildirim // Appl. Soft Computing. 2023. Vol. 133. P. 109945.

7. Gajamannage K., Park Yo., Jayathilake D. I. Real-time forecasting of time series in financial markets using sequentially trained dual-LSTMs // Expert Systems with Appl. 2023. Vol. 223. P. 119879.

8. Dong X., Guo M., Wang Shi. Active control method for the sinking of open caissons: A data-driven approach based on CNN and time series prediction // Ocean Engin. 2022. Vol. 257. P. 111683.

9. Verma Tu. Complete guide to Dickey-Fuller test // Time-Series Analysis. URL: <https://analyticsindiamag.com/complete-guide-to-dickey-fuller-test-in-time-series-analysis> (data obraschenija 12.04.2023).

Information about the authors

Aleksandr V. Eroshkin – Associate Professor of the Department of Automation and Control Processes of Saint-Petersburg Electrotechnical University.

E-mail: eroshkin.a.spb@gmail.com

Maria A. Potapova – master's student graduate school of software engineering of Peter the Great Saint Petersburg Polytechnic University

E-mail: potapova.ma@mail.ru

Aleksandra E. Lonchina – assistant of the Department of Automation and Control Processes of Saint Petersburg Electrotechnical University.

E-mail: sashalonchina@gmail.com

Статья поступила в редакцию 20.06.2023; принята к публикации после рецензирования 28.09.2023; опубликована онлайн 19.12.2023.

Submitted 20.06.2023; accepted 28.09.2023; published online 19.12.2023.
