

Коцюба, И. Ю. Автоматизация поддержки выбора маркетинговой стратегии на основе интеллектуального прогнозирования спроса на услуги / И. Ю. Коцюба, П. А. Алексеев // Прикладная математика и вопросы управления. – 2024. – № 2. – С. 110–122. DOI 10.15593/2499-9873/2024.2.08

**Библиографическое описание согласно ГОСТ Р 7.0.100–2018**

Коцюба, И. Ю. Автоматизация поддержки выбора маркетинговой стратегии на основе интеллектуального прогнозирования спроса на услуги / И. Ю. Коцюба, П. А. Алексеев. – Текст : непосредственный. – DOI 10.15593/2499-9873/2024.2.08 // Прикладная математика и вопросы управления / Applied Mathematics and Control Sciences. – 2024. – № 2. – С. 110–122.



**пермский  
политех** ПРИКЛАДНАЯ МАТЕМАТИКА  
И ВОПРОСЫ УПРАВЛЕНИЯ  
№ 2, 2024

<https://ered.pstu.ru/index.php/amcs>



Научная статья

DOI: 10.15593/2499-9873/2024.2.08

УДК 519.862.7:519.816



## Автоматизация поддержки выбора маркетинговой стратегии на основе интеллектуального прогнозирования спроса на услуги

И.Ю. Коцюба, П.А. Алексеев

Университет ИТМО, Санкт-Петербург, Российская Федерация

### О СТАТЬЕ

Получена: 08 мая 2024  
Одобрена: 20 июня 2024  
Принята к публикации:  
10 июля 2024

#### Финансирование

Исследование не имело спонсорской поддержки.

#### Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

#### Вклад авторов

равноценен.

#### Ключевые слова:

прогнозирование спроса, SARIMA, XGBoosting, рекуррентные нейронные сети, телекоммуникационные услуги, многоуровневое моделирование, сезонность, управление спросом, тарифная политика, точность прогнозов.

### АННОТАЦИЯ

Представлен анализ различных методов прогнозирования спроса для телекоммуникационной компании «Триколор» с использованием как статистической модели SARIMA, так и современных подходов, включая XGBoost и рекуррентные нейронные сети. Исследование охватывает применение этих методов для оценки будущих изменений спроса на тарифные планы, учитывая сезонные колебания и другие влияющие факторы. Освещены вопросы настройки моделей, выбора параметров, а также вызовы и решения, связанные с каждым из методов, чтобы повысить точность прогнозов. Работа подчеркивает значимость интеграции разнообразных методов прогнозирования в стратегическое планирование и оперативное управление компанией в условиях рыночной конкуренции и изменчивости потребительских предпочтений. Результаты могут быть использованы для формирования гибких стратегий управления спросом и оптимизации предложений компании.

© Коцюба Игорь Юрьевич – кандидат технических наук, доцент, факультет инфокоммуникационных технологий, e-mail: gercog91@mail.ru, ORCID 0000-0002-1680-5597.

Алексеев Павел Алексеевич – студент, факультет инфокоммуникационных технологий, e-mail: 1306026@mail.ru, ORCID 0009-0007-2597-8768.



Эта статья доступна в соответствии с условиями лицензии Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

**Perm Polytech Style:** Kotsyuba I.Yu., Alekseev P.A. Automation of marketing strategy selection support based on intelligent demand forecasting for services. *Applied Mathematics and Control Sciences*. 2024, no. 2, pp. 110–122. DOI: 10.15593/2499-9873/2024.2.08

**MDPI and ACS Style:** Kotsyuba, I.Yu.; Alekseev, P.A. Automation of marketing strategy selection support based on intelligent demand forecasting for services. *Appl. Math. Control Sci.* **2024**, **2**, 110–122. <https://doi.org/10.15593/2499-9873/2024.2.08>

**Chicago/Turabian Style:** Kotsyuba, Igor Yu., and Pavel Al. Alekseev. 2024. “Automation of marketing strategy selection support based on intelligent demand forecasting for services”. *Appl. Math. Control Sci.* no. 2: 110–122. <https://doi.org/10.15593/2499-9873/2024.2.08>



APPLIED MATHEMATICS  
AND CONTROL SCIENCES

№ 2, 2024

<https://ered.pstu.ru/index.php/amcs>



Article

DOI: 10.15593/2499-9873/2024.2.08

UDC 519.862.7:519.816



## Automation of marketing strategy selection support based on intelligent demand forecasting for services

I.Yu. Kotsyuba, P.A. Alekseev

ITMO University, Saint Petersburg, Russian Federation

### ARTICLE INFO

Received: 08 May 2024  
Approved: 20 June 2024  
Accepted for publication:  
10 July 2024

#### Funding

This research received no external funding.

#### Conflicts of Interest

The authors declare no conflict of interest.

#### Author Contributions

equivalent.

#### Keywords:

Demand forecasting, SARIMA, XGBoosting, recurrent neural networks, telecommunications services, multilevel modeling, seasonality, demand management, tariff policy, forecast accuracy.

### ABSTRACT

The article presents an analysis of various demand forecasting methods for the telecommunications company "Tricolor", using both the statistical SARIMA model and modern approaches, including XGBoost and recurrent neural networks. The study encompasses the application of these methods to assess future changes in demand for tariff plans, considering seasonal fluctuations and other influencing factors. The article addresses issues related to model tuning, parameter selection, as well as challenges and solutions associated with each method to enhance forecast accuracy. It emphasizes the significance of integrating diverse forecasting methods into strategic planning and operational management of the company in a competitive market environment and variable consumer preferences. The results can be used to form flexible demand management strategies and optimize the company's offerings.

© **Igor Yu. Kotsyuba** – CSc of Technical Sciences, Associate Professor, Faculty of Infocommunicational technologies, e-mail: [gercog91@mail.ru](mailto:gercog91@mail.ru), ORCID 0000-0002-1680-5597.

**Pavel A. Alekseev** – Student, Faculty of Infocommunicational technologies, e-mail: [1306026@mail.ru](mailto:1306026@mail.ru), ORCID 0009-0007-2597-8768.



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

## Введение

В современном мире услуги являются важной частью рынка. По статистике телевидение остается одной из наиболее востребованных услуг, предлагая широкий спектр как стандартных, так и специализированных опций для различных аудиторий. В частности, индивидуализированные телевизионные услуги становятся все более популярными, поскольку они предоставляют возможность настройки контента под личные предпочтения пользователей. Эффективное управление такими услугами требует применения методов предиктивной аналитики и прогнозирования, что особенно актуально в контексте использования интеллектуального анализа данных. Разработка и внедрение продвинутых аналитических инструментов позволяет компаниям не только точно определять потребности своих клиентов, но и предвидеть изменения в предпочтениях, оптимизируя и персонализируя свои предложения в соответствии с трендами рынка и повышая тем самым конкурентоспособность и уровень удовлетворенности пользователей.

Прогнозирование спроса на услуги играет ключевую роль в планировании и стратегическом управлении современных телекоммуникационных компаний. Эффективное прогнозирование позволяет оптимизировать запасы и адаптировать маркетинговые стратегии, реагируя на меняющиеся требования рынка. Для решения задачи прогнозирования могут быть использованы различные методы интеллектуального анализа данных, в данном случае представлен анализ применения статистических и машинных методов прогнозирования спроса, включая модель SARIMA, XGBoosting и рекуррентные нейронные сети на примере телекоммуникационной компании «Триколор» [1].

Подробно описываются процесс подбора оптимальных параметров для каждой модели, использование информационных критериев для оценки качества моделей и методы улучшения прогнозов через оптимизацию. Особое внимание уделяется интеграции данных методов в систему бизнес-аналитики компании для оперативного управления и стратегического планирования, в том числе подбора подходящих маркетинговых стратегий на основе проведенного анализа.

## Анализ временного ряда для тарифа «Детский»

На данном этапе исследования был проведен анализ временных рядов с фокусом на детский тариф телекоммуникационной компании «Триколор». Этот тариф соответствует стратегии фокусирования, так как он ориентирован на четко определенную аудиторию – семьи с детьми, предлагая контент, который адаптирован под их интересы и нужды, что делает его привлекательным выбором для родителей, стремящихся найти безопасные и развивающие программы для своих детей [2–5].

Исходные данные, использованные для анализа, включали более 20 млн записей, из которых были выделены данные для детского тарифа. Предварительная обработка данных включала очистку от аномалий и пропусков и их структуризацию, что упростило последующую работу с ними. Дальнейшие шаги исследования будут включать детальный анализ полученных результатов прогноза, оценку его точности и применение модели для оптимизации маркетинговых стратегий компании. Это позволит не только улучшить понимание рыночных тенденций, но и сформулировать рекомендации по корректировке предложений для удовлетворения изменяющихся потребностей клиентов.

После обработки данных ряд был разложен на компоненты для более детального понимания его движения, которое далее поможет оценить прогноз модели. Разложение представлено на рис. 1.

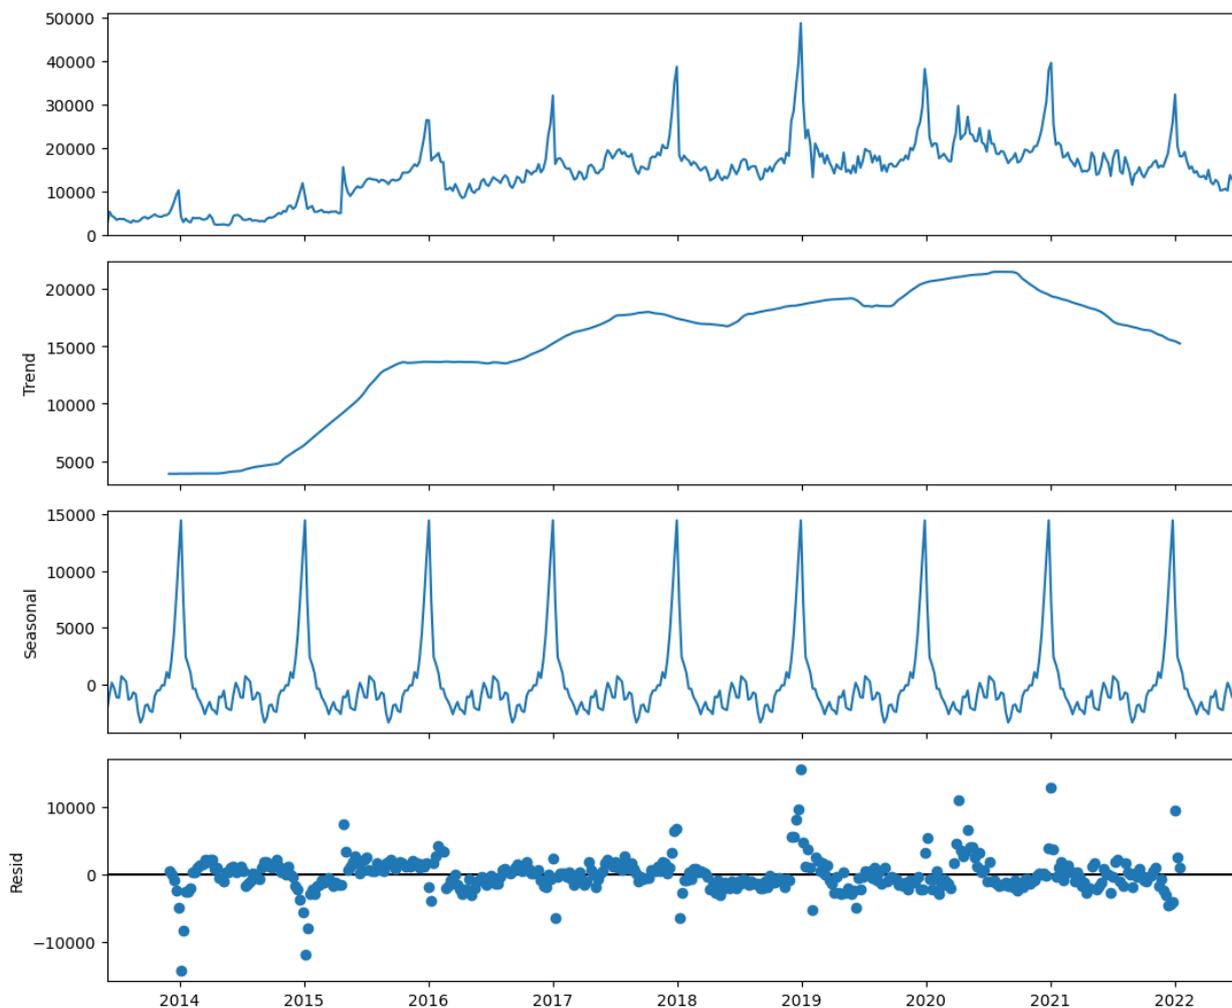


Рис. 1. Разложенный ряд для тарифа «Детский»

Исходя из разложения выше, можно увидеть, что на данном этапе ряд следует в нисходящем тренде и в нем, вероятно, и продолжим дальнейший путь. Сезонность выражается как годовая, на каждый январь приходится годовой экстремум, благодаря чему и возникает сезонность. Остатки временного ряда, равномерно разбросанные вокруг центральной линии без видимых закономерностей, свидетельствуют, что основные трендовые и сезонные компоненты были успешно выделены из данных.

На следующем этапе этот временной ряд будет использоваться для дальнейшего прогнозирования спроса с помощью различных моделей, включая SARIMA, XGBoosting и рекуррентные нейронные сети.

### Прогнозирование спроса на детский тариф с использованием модели машинного обучения XGBoosting

Для того чтобы спрогнозировать значения при помощи XGBoosting, была использована библиотека xgboost [6–8]. А также для более точного прогноза каждому значению исходного ряда были добавлены новые признаки, которые содержали в себе год и порядковый номер недели в году.

Далее ряд был разделен на тренировочную и тестовую выборку в соотношении 80/20 для того, чтобы оценить результат обученной модели.

После этого при помощи метода поиска по сетки были найдены оптимальные параметры для обучения XGBoosting. Параметры были следующие:

- 1) `max_depth`: 5 – максимальная глубина каждого дерева. Ограничение глубины помогает предотвратить переобучение;
- 2) `eta`: 0.05 – темп обучения, который используется для предотвращения переобучения за счет «смягчения» вносимых изменений в модель на каждом шаге;
- 3) `min_child_weight`: 3 – минимальное необходимое количество точек данных в весах потомков. Более высокие значения предотвращают переобучение;
- 4) `subsample`: 0.8 и `colsample_bytree`: 0.8 – параметры, регулирующие долю подвыборки используемых объектов и признаков для построения каждого дерева, что добавляет случайности в модель и помогает уменьшить переобучение;
- 5) `n_estimators`: 1000 и `num_boost_round`: 100 – количество деревьев в модели и число шагов бустинга соответственно.

После подбора параметров модель была обучена и протестирована на тестовой выборке. Результаты тестирования представлены на рис. 2.

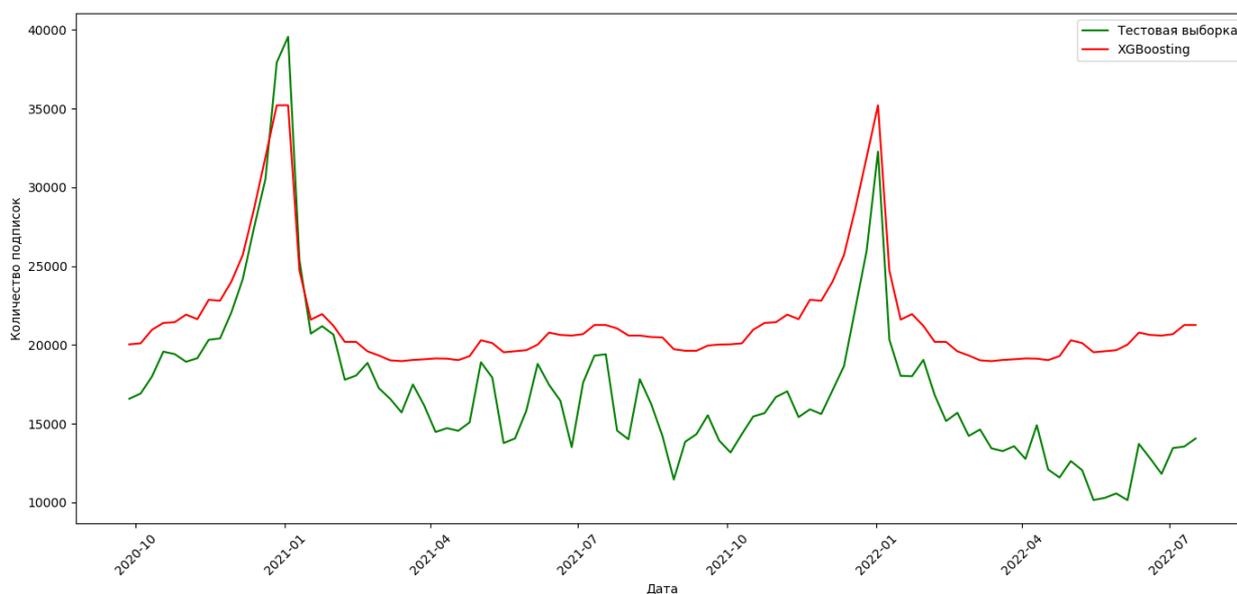


Рис. 2. Результат обученного XGBoosting на тестовой выборке

По рисунку выше видно, что модель способна примерно описывать ряд и его сезонные экстремумы, но то, что происходит между сезонными точками, модель описывает плохо, также это подтверждают и метрики.

Полученные значения метрик, такие как среднеквадратичная ошибка: 5124,21, указывают на значительные ошибки в прогнозах в рамках прогнозирования, что делает модель неэффективной для точного прогнозирования. Эти величины ошибок слишком велики, чтобы можно было считать модель достоверной для практического применения в анализе временных рядов. К тому же значение коэффициента детерминации равно 0.01 говорит о том, что модель не улучшает прогноз, по сравнению с базовой моделью, которая бы использовала среднее значение как прогноз. Это подтверждает, что модель неадекватно описывает зависимости в данных и, следовательно, не подходит для данной задачи прогнозирования.

В связи с такими результатами было принято решение не использовать XGBoosting для дальнейшего прогнозирования, так как это не представляется логичным из-за низкой

точности и эффективности данного метода в нашем случае. Можно с уверенностью сказать, что данный метод не подходит для решения наших задач.

### Анализ и прогнозирование спроса на детский тариф с использованием рекуррентной нейронной сети

На данном этапе начинается обучение рекуррентной нейронной сети, и для улучшения точности прогноза были добавлены новые признаки, такие как скользящая средняя и лаги по 5 последним значениям.

Лагами, в анализе временных рядов называются предыдущие значения в серии, используемые для прогнозирования будущих значений, отстоящих на определенное количество временных шагов. Скользящее среднее – метод усреднения данных временного ряда, помогающий сглаживать краткосрочные колебания и выявлять долгосрочные тренды. Таким образом, нейросеть обучалась на более информативных данных, что способствовало улучшению прогноза.

Рекуррентная нейронная сеть была создана с множественными слоями для сложных задач прогнозирования. Она включает 50 LSTM-нейронов в первом слое, что позволяет сети улавливать долгосрочные паттерны. Дополнительно использование слоя Dropout с коэффициентом 0,2 способствует предотвращению переобучения путем исключения части нейронов на этапе обучения [9–11].

Модель была скомпилирована с использованием оптимизатора Adam и функции потерь mean squared error. Такая конфигурация нацелена на минимизацию ошибок в прогнозах и оптимизацию процесса обучения. Затем была выведена тестовая и прогнозируемая выборка, представленные на рис. 3.

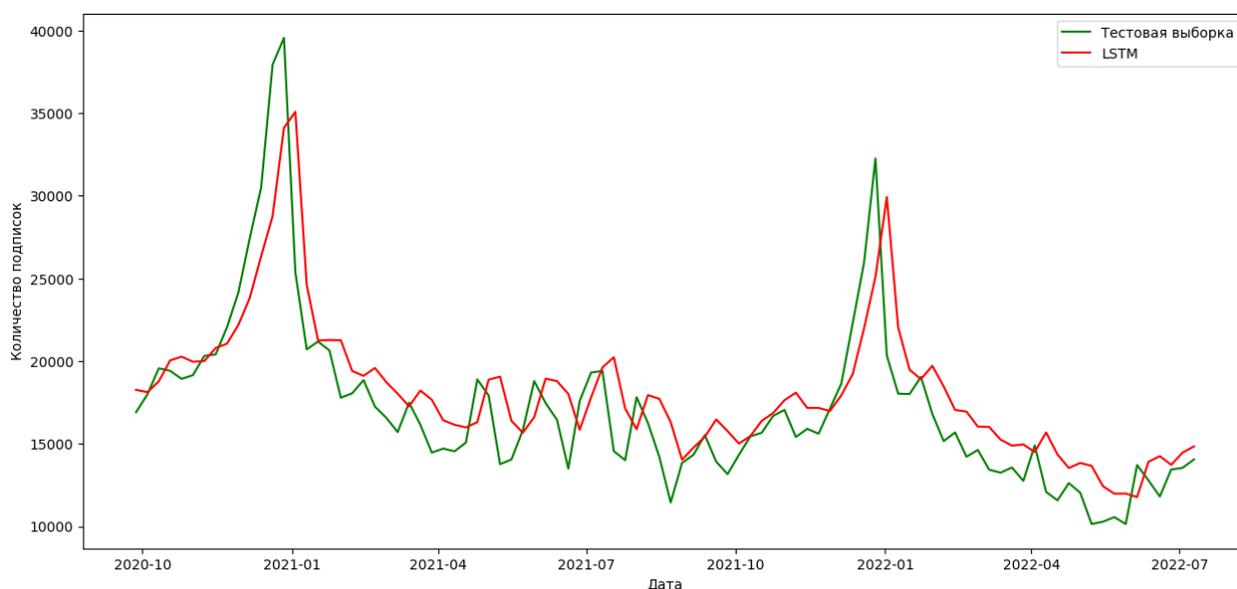


Рис. 3. Обучение рекуррентной нейросети на тестовой выборке

Метрики, полученные для рекуррентной нейронной сети, значительно превосходят результаты, достигнутые при использовании XGBoosting. Среднеквадратичная ошибка составила 2407,87, а коэффициент детерминации достиг значительного уровня 0,78. Эти результаты указывают на высокую степень точности модели в прогнозировании, что делает ее подходящей для практического применения в задачах прогнозирования спроса.

Для дальнейшего прогнозирования была написана функция, которая генерирует новые признаки для каждой последующей даты на основании обученной модели.

В процессе генерации новых данных для будущих прогнозов была выявлена проблема: полученный прогноз оказался слишком сглаженным и следовал лишь сезонным экстремумам, не отражая детальных колебаний между ними. Несмотря на хорошее поведение модели на тренировочных данных, это свидетельствует о недостаточности подхода для реального прогнозирования. Визуализация прогноза представлена на рис. 4.

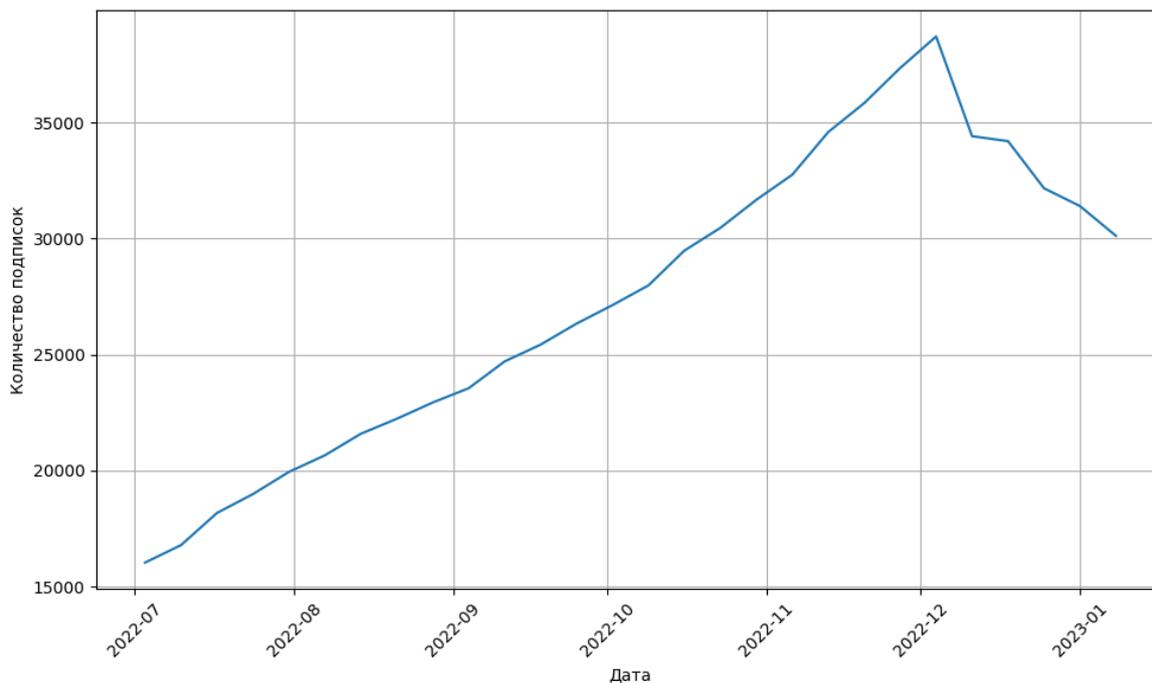


Рис. 4. Прогноз рекуррентной нейросети для тарифа «Детский»

Ключевой момент здесь заключается в том, что при генерации новых данных для прогноза будущих значений используются предсказания модели, а не фактические исторические данные. Это значит, что любые ошибки или неточности в предсказаниях модели кумулятивно влияют на последующие прогнозы, делая их все менее точными и реалистичными. В частности, модель могла эффективно улавливать и предсказывать основные тренды и сезонные пики, но оказалась не способна адекватно реагировать на более мелкие и краткосрочные изменения в данных.

Таким образом, хотя на начальных этапах модель демонстрировала высокую точность на тренировочной выборке, для долгосрочного и динамичного прогнозирования она не подходит. Причиной тому зависимость будущих предсказаний от результатов предыдущих, что приводит к накоплению ошибок и снижению общей точности модели. В результате, несмотря на первоначальные успехи, данный подход был исключен из дальнейшего использования для наших целей.

## Данные и методы

Далее будет представлен оптимальный метод для прогнозирования временных рядов, который способен помочь компаниям при выборе маркетинговых стратегий для максимальной выгоды.

## Анализ и прогнозирование спроса на детский тариф при помощи статистического метода SARIMA

Важно отметить, что SARIMA подходит только для стационарных рядов и перед ее использованием нужно убедиться, является ли таким ряд или нет, если нет, то нужно преобразовать исходный ряд. Для определения стационарности проводится тест Дики – Фуллера, который проверяет нулевую гипотезу о наличии единичного корня в временном ряду, что указывает на то, что ряд стационарен. В результате теста значение  $p$ -value было выше стандартного значения, равного 0,05, и для дальнейшей работы необходимо дифференцировать ряд для того, чтобы это значение стало меньше. После первого дифференцирования ряд стал стационарным [12; 13].

Далее ряд готов для того, чтобы начать прогнозирование, поэтому следующим этапом стала подборка параметров при помощи метода `auto_arima`, содержащемся в библиотеке `pydarima`. Данный метод подбирает оптимальные параметры, опираясь на наименьший коэффициент AIC, который является статистическим показателем, используемым для оценки качества моделей на основе их сложности и способности объяснять данные, при этом штрафует модель за чрезмерное количество параметров. Подбирались следующие параметры:

1) AR –  $p$ : этот компонент модели представляет собой регрессию текущего значения временного ряда на его предыдущие значения. Параметр  $p$  указывает количество лагов, используемых в модели;

2) I –  $d$ : данный компонент модели свидетельствует о том, какое количество раз данные временного ряда должны быть дифференцированы для достижения стационарности. Стационарный ряд характеризуется постоянными во времени статистическими свойствами, такими как среднее значение и дисперсия;

3) MA –  $q$ : этот компонент использует предыдущие ошибки прогноза для описания временного ряда. Параметр  $q$  обозначает количество лагов ошибок прогноза, включенных в модель;

4) Сезонные компоненты P, D, Q на период  $s$ : эти термины аналогичны  $p$ ,  $d$ ,  $q$ , но применяются к сезонным данным. P – сезонный порядок регрессии, D – сезонный порядок дифференцирования, Q – сезонный порядок ошибки прогноза, и  $s$  – длина сезонного периода.

В результате автоподбора были получены оптимальные параметры и коэффициенты обученной модели, которые представлены на рис. 5.

| SARIMAX Results         |                                 |          |                   |           |          |          |
|-------------------------|---------------------------------|----------|-------------------|-----------|----------|----------|
| =====                   |                                 |          |                   |           |          |          |
| Dep. Variable:          | SAP_ALL0_ID                     |          | No. Observations: | 109       |          |          |
| Model:                  | SARIMAX(1, 1, 1)x(1, 1, [], 12) |          | Log Likelihood    | -1015.311 |          |          |
| Date:                   | Wed, 01 May 2024                |          | AIC               | 2038.623  |          |          |
| Time:                   | 18:02:56                        |          | BIC               | 2048.880  |          |          |
| Sample:                 | 06-30-2013                      |          | HQIC              | 2042.769  |          |          |
|                         | - 06-30-2022                    |          |                   |           |          |          |
| Covariance Type:        | opg                             |          |                   |           |          |          |
| =====                   |                                 |          |                   |           |          |          |
|                         | coef                            | std err  | z                 | P> z      | [0.025   | 0.975]   |
| -----                   |                                 |          |                   |           |          |          |
| ar.L1                   | 0.7637                          | 0.137    | 5.586             | 0.000     | 0.496    | 1.032    |
| ma.L1                   | -0.9218                         | 0.086    | -10.701           | 0.000     | -1.091   | -0.753   |
| ar.S.L12                | -0.3494                         | 0.084    | -4.165            | 0.000     | -0.514   | -0.185   |
| sigma2                  | 8.982e+07                       | 6.71e-10 | 1.34e+17          | 0.000     | 8.98e+07 | 8.98e+07 |
| =====                   |                                 |          |                   |           |          |          |
| Ljung-Box (L1) (Q):     | 0.12                            |          | Jarque-Bera (JB): | 30.17     |          |          |
| Prob(Q):                | 0.73                            |          | Prob(JB):         | 0.00      |          |          |
| Heteroskedasticity (H): | 1.67                            |          | Skew:             | 0.63      |          |          |
| Prob(H) (two-sided):    | 0.15                            |          | Kurtosis:         | 5.44      |          |          |
| =====                   |                                 |          |                   |           |          |          |

Рис. 5. Результаты лучших параметров SARIMA для детского тарифа

На рис. 5 видны основные параметры и их значения, сфокусируемся на основных статистических параметрах, которые показывают, как хорошо модель обучена:

1) Prob(Q): 0.73 – значение  $p$ -value теста Ljung-Box, которое указывает на адекватность остатков модели. Высокое значение  $p$ -value свидетельствует, что остатки модели можно рассматривать как «белый шум», то есть они не показывают явных автокорреляций, что является хорошим признаком адекватности модели;

2) Prob(H): 0.15 – тест на гомоскедастичность показал, что нет статистически значимых признаков гетероскедастичности, то есть дисперсия остатков модели стабильна;

3) показатели для всех коэффициентов  $P > |z|$  меньше 0,05, это свидетельствует, что все коэффициенты модели статистически значимы и вероятность получения таких или более экстремальных значений случайным образом очень мала, подтверждая адекватность модели в описании данных.

После успешного обучения рассмотрим, какие прогнозы модель выдает для тестовой выборки. На рис. 6 представлена визуализация результатов.

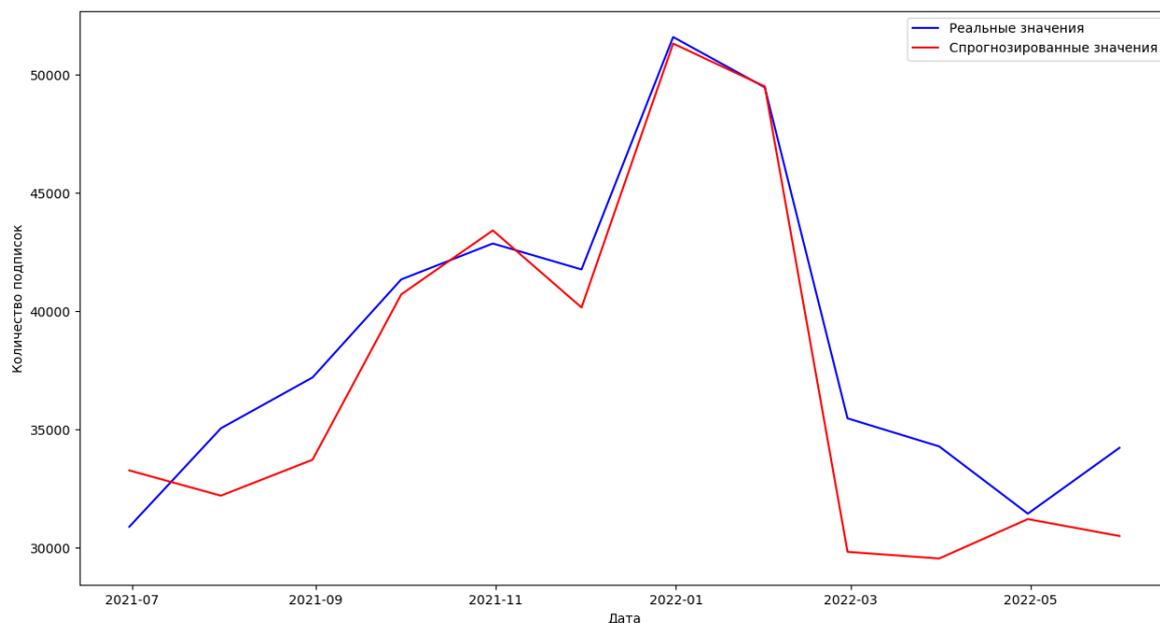


Рис. 6. Прогноз на тестовой выборке для тарифа «Детский»

Видно, что модель способна очень четко улавливать движение тренда, а также сезонности и не сглаживает результаты между сезонными экстремумами, а описывает кол-во подписок близко к реальным значениям.

На представленном графике четко видна способность модели детально отслеживать тренд и сезонные колебания спроса, при этом она не прибегает к излишнему сглаживанию данных между сезонными пиками и впадинами, а представляет количество подписок в тесном соответствии с реальными значениями. Это подтверждается полученными метриками: коэффициент детерминации равен 0,85, что указывает на высокую долю объясненной моделью вариативности данных, а среднеквадратичная ошибка составляет 5428, что в контексте нашего временного ряда, который теперь имеет месячное распределение, а не недельное, со значительно более высокими данными, является приемлемым показателем точности. Учитывая среднеквадратичное отклонение, можно утверждать, что в среднем модель ошибается на 5428 единиц относительно фактических значений подписок, что в

рамках данного анализа считается достаточно хорошим показателем, поскольку позволяет с уверенностью прогнозировать общие тенденции спроса [14; 15].

## Полученные результаты

В связи с высокой степенью точности и надежности обученной модели SARIMA будем использовать ее для прогнозирования дальнейшего спроса на предстоящие полгода. Прогноз, основанный на данных, которыми модель была обучена, даст возможность оценить будущие тенденции и, таким образом, принимать более взвешенные и информированные решения в планировании маркетинговых и бизнес-стратегий компании. Рассмотрим, как модель предскажет данные до конца года. Итоговый прогноз представлен на рис. 7.



Рис. 7. Будущий прогноз для тарифа «Детский»

По графику рис. 7 видно, что модель смогла выделить сезонный экстремум, который идет в конце года, а также указала спад, который идет после него. Исходя из такого результата, можно доверять модели и считать ее прогноз валидным на фоне других моделей.

В текущей маркетинговой стратегии компании «Триколор» для детского тарифа используется подход фокусирования, который направлен на определенный сегмент рынка, а именно семьи с детьми. Этот тариф предоставляет контент, специально адаптированный под интересы и нужды младшей аудитории. Однако анализ прогнозов показывает продолжающееся снижение интереса к данному тарифу, что требует пересмотра текущей стратегии для улучшения маркетинговой компании.

Для улучшения ситуации предлагается следующее:

1) дифференциация: стратегия дифференциации, благодаря этой стратегии предлагается внедрить уникальные предложения или эксклюзивный контент, который отличал бы тариф от предложений конкурентов. Можно рассмотреть добавление эксклюзивных образовательных программ или коллабораций с популярными брендами детских товаров, которые сейчас в трендах у детей. Это поможет увеличить восприятие уникальности тарифа и его привлекательности на рынке;

2) фокусирование на уточненной целевой аудитории: фокус на более определенной группе пользователей поможет углубить анализ потребностей конкретных групп потребителей, таких как молодые семьи или семьи с детьми определенного возраста, и разработать

тарифные планы, которые максимально соответствуют их запросам. Это может включать специализированные предложения или бонусы, которые делают тариф более привлекательным для этой категории клиентов.

Такие изменения в стратегии способны помочь повысить интерес к детскому тарифу и улучшить его рыночные позиции, адаптируясь к изменениям в потребностях и предпочтениях целевой аудитории, что, в свою очередь, способствует увеличению клиентской базы и улучшению общего уровня удовлетворенности сервисом.

## Обсуждение

Модель SARIMA позволяет проводить точное прогнозирование временных рядов с учетом сезонности, что критически важно в таких областях, как телекоммуникационные услуги и рынок труда. Эта модель эффективно интегрирует компоненты сезонной авторегрессии, интегрирования и скользящего среднего, обеспечивая глубокое понимание долгосрочных и краткосрочных трендов. SARIMA позволяет описывать сложные временные ряды, в которых уровень и динамика изменений данных могут быть предсказаны с учетом предшествующих значений и сезонных колебаний. Однако ограничения модели SARIMA включают зависимость от правильности подбора начальных параметров и стационарности временного ряда. Для эффективного использования SARIMA требуется тщательный анализ исходных данных на предмет выбора оптимальной конфигурации параметров модели, что может потребовать экспертных знаний и использования статистических методов для определения стационарности и сезонности. Это делает модель особенно чувствительной к изменениям в данных, требующим постоянной корректировки параметров для поддержания точности прогнозов.

## Заключение

Методика прогнозирования временных рядов с использованием модели SARIMA позволяет точно анализировать и предсказывать поведение рыночных данных, основываясь на исторических значениях и учете сезонности. Эта модель интегрирует элементы сезонной авторегрессии и скользящего среднего, что делает ее незаменимым инструментом в руках аналитиков для оценки и прогнозирования рыночных тенденций. SARIMA позволяет формализовать процесс анализа данных, обеспечивая высокую точность и надежность прогнозов, что критически важно для стратегического планирования и управления ресурсами в условиях меняющегося рынка.

## Список литературы

1. Компания Триколор [Электронный ресурс]. – 2024. – URL: <https://www.tricolor.ru/about/> (дата обращения: 08.05.2024).
2. Chernykh, M.A. Маркетинговый менеджмент поведения клиентов на рынке услуг / М.А. Chernykh // Державинские чтения: материалы XXII Всероссийской научной конференции. – 2017. – С. 180–187.
3. Есимжанова, С.Р. Формирование маркетинговой коммуникационной стратегии компании / С.Р. Есимжанова, Д.Е. Сейфуллина // Наука и образование сегодня. – 2021. – № 5 (64). – С. 21–25.
4. Пэйен, Ц. Трансформация российского производства телепрограмм в эпоху искусственного интеллекта / Ц. Пэйен // Современные инновации. – 2020. – № 2 (36). – С. 49–51.

5. Что такое маркетинговые стратегии и как ее разобрать: Яндекс Практикум [Электронный ресурс]. – 2024. – URL: <https://practicum.yandex.ru/blog/marketingovye-strategii/#vidy> (дата обращения: 08.05.2024).
6. Волошин, Т.А. Применение адаптивных ансамблей методов машинного обучения к задаче прогнозирования временных рядов / Т.А. Волошин, К.С. Зайцев, М.Е. Дунаев // *International Journal of Open Information Technologies*. – 2023. – № 8. – С. 57–63.
7. Васина, Д.И. Обзор и апробирование методов машинного обучения для краткосрочного прогнозирования / Д.И. Васина // *МСИМ*. – 2023. – № 4 (68). – С. 59–70.
8. Флах, П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / П. Флах. – М.: ДМК Пресс, 2015. – 400 с.
9. Якименко, В.В. Архитектура модели LSTM для прогнозирования временных рядов редких событий / В.В. Якименко, И.Л. Савостьянова // *Актуальные проблемы авиации и космонавтики*. – 2022. – С. 533–535.
10. Нейронные сети, генетические алгоритмы и нечеткие системы: Электронно-библиотечная система. Издательство «Лань» [Электронный ресурс] – 2013. – URL: [http://e.lanbook.com/books/element.php?pl1\\_cid=25&pl1\\_id=11843](http://e.lanbook.com/books/element.php?pl1_cid=25&pl1_id=11843) (дата обращения: 16.04.2024).
11. Программирование искусственного интеллекта в приложениях: Электронно-библиотечная система. Издательство «Лань» [Электронный ресурс] – 2011. – URL: [http://e.lanbook.com/books/element.php?pl1\\_cid=25&pl1\\_id=1244](http://e.lanbook.com/books/element.php?pl1_cid=25&pl1_id=1244) (дата обращения: 17.04.2024).
12. Игнатов, Н.А. Прогнозирование временных рядов с регулярными циклическими компонентами с помощью модели периодически коррелированных случайных процессов / Н.А. Игнатов // *Научные труды: Институт народнохозяйственного прогнозирования РАН*. – 2011. – № 9. – С. 461–477.
13. Миролюбова, А.А. ARIMA – прогнозирование спроса производственного предприятия / А.А. Миролюбова, А.Д. Ермолаев, М.Б. Прокофьев // *Современные наукоемкие технологии. Региональное приложение*. – 2021. – № 2 (66). – С. 50–55.
14. Альчаков, В.В. Оценка методов машинного обучения для прогнозирования сезонных временных рядов / В.В. Альчаков, В.А. Крамарь // *известия юфу. Технические науки*. – 2023. – № 2 (232). – С. 250–263.
15. Метрики оценки алгоритмов автоматического сопровождения / А.Е. Щелкунов, В.В. Ковалев, К.И. Морев, И.В. Сидько // *Известия ЮФУ. Технические науки*. – 2020. – № 1 (211). – С. 233–245.

## References

1. Kompaniya Tricolor, available at: <https://www.tricolor.ru/about/> (accessed 08 May 2024).
2. Chernykh M.A. Marketingovyy menedzhment povedeniya klientov na rynke uslug. V sbornike: Derzhavinskie chteniya. materialy XXII Vserossiyskoy nauchnoy konferentsii. 2017, pp. 180-187.
3. Esimzhanova S.R. Seyfullina D.E. Formirovanie marketingovoy kommunika-tсионной стратегии компании. *Nauka i obrazovanie segodnya*. 2021, no. 5 (64), pp 21-25.
4. Peyen Ts. Transformatsiya rossiyskogo proizvodstva teleprogramm v epokhu is-kusstvennogo intellekta. *Sovremennye innovatsii*. 2020, no. 2 (36), pp. 49-51.
5. Chto takoe marketingovye strategii i kak ee razobrat.: Yandeks Praktikum, available at: <https://practicum.yandex.ru/blog/marketingovye-strategii/#vidy> (Accessed 08 May 2024)
6. Voloshin T.A. Zaytsev K.S. Dunaev M.E. Primenenie adaptivnykh ansambley metodov mashinnogo obucheniya k zadache prognozirovaniya vremennykh ryadov. *International Journal of Open Information Technologies*. 2023, no. 8, pp. 57-63.

7. Vasina D.I. Obzor i aprobirovaniye metodov mashinnogo obucheniya dlya kratkorochnogo prognozirovaniya. *MSiM*. 2023, no.4 (68), pp. 59-70.
8. Flakh P. Mashinnoe obucheniye. Nauka i iskusstvo postroeniya algoritmov, ko-torye izvlekayut znaniya iz dannykh. Moscow: DMK Press, 2015, 400 p.
9. Yakimenko V.V. Savostyanova I.L. Arkhitektura modeli LSTM dlya prognozirovaniya vremennykh ryadov redkikh sobyiy. *Aktualnye problemy aviatsii i kosmonavтики*. 2022, pp. 533-535.
10. Neyronnye seti, geneticheskie algoritmy i nechetkie sistemy, available at: [http://e.lanbook.com/books/element.php?pl1\\_cid=25&pl1\\_id=11843](http://e.lanbook.com/books/element.php?pl1_cid=25&pl1_id=11843) (Accessed 16 April 2024)
11. Programmirovaniye iskusstvennogo intellekta v prilozheniyakh.: Elektronno-bibliotecnaya sistema. Izdatelstvo «Lan», 2011. available at: [http://e.lanbook.com/books/element.php?pl1\\_cid=25&pl1\\_id=1244](http://e.lanbook.com/books/element.php?pl1_cid=25&pl1_id=1244) (Accessed 17 April 2024)
12. Ignatov N.A. Prognozirovaniye vremennykh ryadov s regulyarnymi tsikliche-skimi komponentami s pomoshchyu modeli periodicheski korrelirovannykh sluchaynykh protsessov. *Nauchnye trudy: Institut narodnokhozyaystvennogo prognozirovaniya RAN*. 2011, no. 9, pp. 461-477.
13. Mirol'yubova A.A. Ermolaev A.D. Prokofyev M.B. ARIMA - prognozirovaniye sprosa proizvodstvennogo predpriyatiya. *Sovremennyye naukoemkie tekhnologii. Regionalnoe prilozhenie*. 2021, no. 2 (66), pp 50-55.
14. Alchakov V.V. Kramar V.A. Otsenka metodov mashinnogo obucheniya dlya prognozirovaniya sezonnykh vremennykh ryadov. *Izvestiya YuFU. Tekhnicheskie nauki*. 2023, no. 2 (232), pp 250-263.
15. Shchelkunov A.E, Kovalev V.V. Morev K.I. Sidko I.V. Metriki otsenki algoritmov avtomaticheskogo soprovozhdeniya. *Izvestiya YuFU. Tekhnicheskie nauki*. 2020, no. 1 (211), pp. 233-245.