

**З.В. Архипова***Байкальский государственный университет,  
г. Иркутск, Российская Федерация***Д.Д. Федькина***Байкальский государственный университет,  
г. Иркутск, Российская Федерация*

## **Современные подходы к выбору метода анализа и прогнозирования веб-трафика в интернет-маркетинге**

**Аннотация.** Стремительное развитие систем искусственного интеллекта требует рационального и взвешенного подхода к его применению и внедрению в различные сферы экономики. Анализ и прогнозирование веб-трафика в интернет-маркетинге играет важную роль и способствует сокращению издержек и эффективному использованию рекламного бюджета. В статье рассмотрены вопросы выбора метода для анализа веб-трафика. Актуальность исследования обусловлена тем, что в ней рассмотрены как традиционные статистические и эконометрические методы, так и нейронные сети, с рекомендациями по их применению. Методология исследования основана на теоретических и экспериментальных методах анализа и прогнозирования веб-трафика. Информационной и эмпирической базой исследования послужили статистические данные платформы веб-аналитики Яндекс.Метрика компании дистрибьютера в сфере поставок продуктов питания за трёхлетний период. Теоретическая и практическая значимость заключается в том, что проведенное исследование позволило сравнить ряд методов прогнозирования веб-трафика и классификации источников трафика, среди которых использованы как классические статистические модели (ARIMA, SARIMA, Holt-Winters), так и современные методы машинного обучения и нейросетевые решения (Prophet, LSTM, GRU, Fully Connected, Decision Tree, Random Forest, линейная регрессия с календарными признаками). Проведённое исследование показало, что наиболее эффективен комплексный подход, объединяющий классические и современные нейросетевые методы, позволяющий повысить точность прогнозов и глубину анализа веб-трафика.

**Ключевые слова.** Веб-трафик, прогнозирование, нейросетевые технологии, ARIMA, SARIMA, Exponential Smoothing, Prophet, LSTM, GRU, классификация, ансамблевые методы, интернет-маркетинг.

**Информация о статье.** Дата поступления: 26 марта 2025 г.; дата принятия к публикации: 11 июня 2025 г.; дата онлайн-размещения: 8 июля 2025 г.

**Z.V. Arkhipova***Baikal State University,  
Irkutsk, Russian Federation***D.D. Fedkina***Baikal State University,  
Irkutsk, Russian Federation*

## **Modern Approaches to Choosing a Method of Analyzing and Forecasting Web Traffic in Internet Marketing**

**Abstract.** The rapid development of artificial intelligence systems requires a rational and well-balanced approach to their application and implementation in various sectors of the economy. Analyzing and forecasting web traffic in internet marketing plays a key role and contributes to cost reduction and more efficient use of advertising budgets. This article addresses the choice of method for analyzing web-traffic. The relevance of the research is determined by the fact that it examines both traditional statistical and econometric methods, as well as neural networks, providing recommendations for their application. The research methodology is based on theoretical and experimental approaches to analyzing and forecasting web-traffic. The information and empirical base of the study consists of statistical data from the Yandex.Metrica web analytics platform for a distribution company operating in the food supply sector over a three-year period. The theoretical and practical significance lies in the fact that the study compares a range of web-traffic forecasting and traffic source classification methods, including classical statistical models (ARIMA, SARIMA, Holt-Winters) and modern machine learning and neural network solutions (Prophet, LSTM, GRU, Fully Connected, Decision Tree, Random Forest, linear regression with calendar features). The study demonstrates that the most effective strategy is a comprehensive approach combining both classical and modern neural network methods, thereby improving forecasting accuracy and deepening web-traffic analysis.

**Keywords.** Web-traffic, forecasting, neural network technologies, ARIMA, SARIMA, Exponential Smoothing, Prophet, LSTM, GRU, classification, ensemble methods, internet marketing.

**Article info.** Received 26 March, 2025; Accepted 11 June, 2025; Available online 8 July, 2025.

В эпоху глобальной цифровизации и стремительного развития онлайн-бизнеса задачи анализа веб-трафика приобретают важное значение, поскольку способствуют сокращению издержек на интернет-маркетинг и эффективному использованию рекламного бюджета. Организации всё чаще нуждаются в детальном понимании, каким образом пользователи находят их сайты и как распределяются различные каналы трафика: поисковые системы, прямые заходы, реферальные ссылки, социальные сети, мессенджеры, почтовые рассылки и др.

Веб-трафик — это количество посетителей и их взаимодействие с веб-сайтом, что является ключевым показателем его популярности, вовлеченности пользователей и способности приносить доход за счет рекламы или прямых продаж. Анализ и прогнозирование веб-трафика в интернет-маркетинге играет важную роль и

способствует сокращению издержек и эффективному использованию рекламного бюджета.

Компания ООО ТД Элит Трейд специализируется на продаже продуктов питания, в том числе и онлайн. Существенная часть расходов предприятия приходится на рекламу, однако распределение рекламного бюджета между различными каналами веб-трафика не всегда оказывается эффективным. Это обусловлено сложностью анализа и прогнозирования эффективности каждого канала, что требует применения современных математических методов и специальных навыков в области обработки данных.

Как показала практика, традиционные статистические и эконометрические методы и модели, такие как ARIMA, могут давать неплохие результаты при несложных временных рядах, однако по мере увеличения объёма и сложности данных они часто оказываются недостаточно точными или требуют трудоёмкой настройки. Нейросетевые технологии, в частности глубокое обучение (Deep Learning), позволяют выявлять сложные скрытые закономерности, интегрируя знания из разных источников, что делает их особенно привлекательными для решения подобных задач.

Целью данного исследования является выбор наиболее эффективных методов анализа и прогнозирования веб-трафика. Для достижения цели необходимо было решить следующие задачи:

- разработать методику сбора и предобработки данных из Яндекс.Метрики — сервиса веб-аналитики, который позволяет оценить посещаемость сайтов и поведение пользователей на них;
- создать и обучить нейросетевые модели (Fully Connected, RNN) для классификации и прогнозирования трафика;
- провести сравнительный анализ традиционных методов прогнозирования трафика и современных нейросетевых подходов;
- исследовать методы объяснимости для интерпретации полученных результатов;
- сформулировать рекомендации по применению методов.

Обзор научной литературы по исследуемой проблеме показал, что современные работы по применению нейросетей в веб-аналитике часто фокусируются на задачах классификации источников и прогнозирования динамики посещений [1; 2]. Глубокие архитектуры (DNN, RNN, CNN) показали высокую эффективность при обработке больших массивов данных, особенно когда источники трафика сильно различаются по характеру и объёму (поисковый трафик, социальные сети и т.д.). Кроме того, гибридные подходы на стыке методов машинного обучения и статистики становятся всё более востребованными. Например, в [3] авторы комбинируют LSTM с методами самообучающихся карт (SOM) для детектирования аномалий в веб-трафике, что позволяет одновременно решать задачу прогнозирования и кластеризации.

Традиционные статистические методы прогнозирования широко использовались задолго до появления глубоких нейронных сетей и продолжают применяться в промышленной аналитике. К ним относятся:

1. Линейная регрессия. Простой и понятный метод, который хорошо подходит для выявления линейных связей между факторами (например, сезонность или день недели) и объёмом трафика. Однако он слабо устойчив к нелинейным взаимосвязям и многомерным зависимостям. Применение множественной линейной регрессии для прогноза веб-трафика e-commerce сайта детально рассмотрено в [4].

2. ARIMA (AutoRegressive Integrated Moving Average) и её расширения (SARIMA, ARIMAX) ориентированы на анализ стационарных временных рядов с учётом авторегрессии и скользящего среднего. Хотя такие модели нередко обеспечивают приемлемые результаты, они требуют ручной настройки параметров, а также имеют ограничения при наличии резких всплесков посещений (например, в период рекламных кампаний [5].

3. Экспоненциальное сглаживание (Exponential Smoothing). Данный метод легко реализуется и интерпретируется, однако может давать неточные результаты при резких скачках трафика и сложных сезонных паттернах [6].

4. Модели расширенной сезонности, такие как Prophet от Facebook<sup>1</sup>, сочетают в себе свойства аддитивных моделей и позволяют учитывать несколько типов сезонности (ежедневную, еженедельную, годовую и т. д.) [7]. Prophet отличается простотой использования, но иногда приводит к упрощённым прогнозам, поскольку может игнорировать нелинейные зависимости при резких маркетинговых активностях.

Несмотря на широкое распространение, традиционные методы имеют общий недостаток: они либо ограничиваются предположением о стационарности рядов, либо требуют значительной экспертизы для корректной настройки параметров. С ростом числа факторов (тип устройства, география, характер поведения пользователя на сайте, тематические события и т.д.) классические методы начинают проигрывать по точности и масштабируемости нейросетевым моделям [2].

Для проведения исследования были использованы данные из Яндекс.Метрики компании ООО ТД Элит Трейд за период в три года. Доступ к показателям осуществлялся через Reporting API и Logs API, после чего данные подверглись очистке, преобразованию типов и формированию необходимых признаков. На рис. 1 представлена общая характеристика полученной выборки.

<sup>1</sup> Признаны экстремистскими организациями и запрещены на территории РФ.

Всего строк в выборке: 77234

Пример выгруженных данных:

	Date	TrafficSource	DeviceCategory	Region	Country	\
0	2023-11-10	Прямые заходы	Смартфоны	Россия		
1	2024-08-18	Переходы по рекламе	Смартфоны	Россия		
2	2024-03-27	Прямые заходы	Смартфоны	Россия		
3	2024-02-02	Переходы из поисковых систем	Смартфоны	Россия		
4	2023-12-09	Прямые заходы	Смартфоны	Россия		

	Visits	PageViews	BounceRate
0	2068.0	13061.0	8.800774
1	1822.0	3284.0	45.664105
2	1240.0	9427.0	9.677419
3	1215.0	4870.0	36.049383
4	1187.0	11078.0	8.003370

Рис. 1. Общая характеристика выборки данных

Для первичного понимания динамики и структуры трафика были построены несколько ключевых графиков, позволяющих наглядно оценить общие тенденции за выбранный период в три года. На рис. 2 отражена общая динамика визитов за 3 года.





Рис. 2. Общая динамика визитов за 3 года

В рамках исследования проводилось сравнение традиционного статистического подхода Prophet (Meta, Facebook<sup>2</sup>), учитывающего тренд и годовую/недельную сезонность, и рекуррентная нейронная сеть LSTM (Long Short-Term Memory), способная моделировать долгосрочные зависимости во временных рядах.

После обучения Prophet был построен 30-дневный прогноз (рис. 3), где чёрные точки соответствуют фактическим значениям, а синяя линия с доверительным интервалом — предсказанным.

Эксперимент показал, что Prophet хорошо улавливает долгосрочные тенденции и сезонные паттерны (недельные, го-

<sup>2</sup> Признаны экстремистскими организациями и запрещены на территории РФ.




*Рис. 3. Прогноз на 30 дней вперёд (Prophet)*

довые, суточные), и предоставляет интерпретируемую декомпозицию прогноза. Основное ограничение — предположение о регулярности сезонности, что снижает точность при внезапных аномалиях (например, вирусных кампаниях). Для учёта таких событий могут потребоваться дополнительные данные (праздники, исторические акции, маркетинговые кампании). Также Prophet продемонстрировала базовую возможность оценивать динамику трафика на среднесрочную перспективу, выявляя ключевые точки сезонности и тренда, а также предоставляя прозрачную интерпретацию.


Для более гибкого анализа краткосрочных и нелинейных закономерностей была применена рекуррентная нейронная сеть LSTM (рис. 4). Она способна учитывать широкий набор признаков (включая праздничные дни и рекламные кампании) и хорошо адаптируется к рядам с регулярной сезонностью. Однако при резких всплесках трафика могут понадобиться большие объёмы исторических данных и более сложные архитектуры (stacked LSTM, GRU, механизмы внимания).

LSTM показала высокую эффективность и может использоваться совместно с Prophet или классическими статистическими методами, формируя ансамбль для повышения точности и надёжности прогнозов.

В дополнение к задаче прогнозирования была поставлена цель классифицировать тип источника трафика. На рис. 5, мы видим, что функция потерь постепенно снижается, а точность стабильно растёт без признаков переобучения.



**Рис. 4. Прогноз трафика (LSTM)**



**Рис. 5. Кривые обучения (Loss и Accuracy)**

Финальная точность на тестовой выборке свидетельствует о достаточно уверенной классификации источников трафика, хотя результаты можно улучшить, добавив дополнительные признаки и скорректировав гиперпараметры. Полносвязная нейронная сеть способна эффективно обобщать признаки (день недели, месяц, показатели отказов и т.д.) для определения источников трафика. Точность классификации во многом зависит от качества и детализации исходных данных, а также от баланса классов. Графики обучения (рис. 7) показывают стабильное поведение модели и отсутствие существенного переобучения. Для дальнейшего повышения точности можно расширять набор признаков (UTM-метки, более детальная география), увеличивать глубину сети или применять ансамблевые методы (Random Forest, Gradient Boosting).


Таким образом, при грамотной предобработке данных нейросетевые методы с высокой точностью могут классифицировать источники трафика и могут использоваться как дополнительный инструмент веб-аналитики.




Далее для прогноза веб-трафика была проверена модель ARIMA (AutoRegressive Integrated Moving Average), рассчитанная на стационарные временные ряды. Данные делились на тренировочную (80 %) и тестовую (20 %) выборки, после чего модель ARIMA (1,1,1) обучалась на тренировочном промежутке.

В качестве метрик использовались MSE (Mean Squared Error — среднеквадратичная ошибка) и RMSE (Root Mean Squared Error — корень из среднеквадратичной ошибки прогноза).

На тестовых данных (рис. 6) итоговая RMSE достигла примерно 1008, что свидетельствует о существенном расхождении между реальными и предсказанными значениями: модель фактически выдавала усреднённый прогноз, игнорируя резкие колебания.



**Рис. 6. Прогноз трафика с использованием модели ARIMA**




**Рис. 7. Прогноз трафика с использованием модели SARIMA**



Таким образом, модель ARIMA без учёта сезонности и внешних факторов даёт лишь базовый уровень прогноза, а SARIMA помогает отчасти учесть повторяющиеся колебания. Однако обе модели склонны сглаживать резкие скачки и требуют дальнейшей настройки, например, добавления регрессоров (праздники, рекламные кампании) или перехода к более продвинутым методам (Prophet, LSTM, гибридные решения).

В рамках экспериментов была протестирована модель Exponential Smoothing (Holt-Winters), позволяющая одновременно учитывать тренд и сезонность в ряде веб-трафика. Для данных за три года применялся недельный цикл, аддитивный тренд, мультипликативная сезонность и демпфирование тренда. Обучающая часть составляла 80 %, тестовая — 20 %.

На рис. 8 показан итоговый прогноз (зелёная линия), наложенный на реальные (оранжевая) и обучающие (синяя) данные. RMSE составила около 975, что говорит о заметном расхождении при резких скачках: модель учитывает недельную сезонность, но сглаживает аномальные пики, если они не повторяются регулярно. Её достоинствами являются простота настройки и небольшие вычислительные затраты, а к недостаткам относится невозможность напрямую учитывать внешние факторы (рекламные кампании, праздники) и склонность к усреднению аномалий.




**Рис. 8. Прогноз трафика Exponential Smoothing**

Таким образом, Holt-Winters подходит в качестве базового метода при относительно плавном тренде и регулярной сезонности, но при сложных паттернах веб-трафика и необходимости более точного прогноза стоит рассмотреть более гибкие алгоритмы (Prophet, SARIMA, LSTM) или дополнить модель учётом дополнительных факторов.

В числе прочих методов и моделей (ARIMA, SARIMA, Holt-Winters, Prophet, LSTM) была опробована линейная регрессия, обогащённая календарными и лаговыми признаками. Это позволяло учесть сезонность (например, пики в будни и спады в выходные), а также краткосрочные зависимости от предыдущих дней. Данные делились на тренировочную (80 %) и тестовую (20 %). Для обучения использовалась базовая LinearRegression из библиотеки sklearn без регуляризации (Ridge/Lasso).

На рис. 9 показаны фактические значения (синяя линия) и предсказанные (оранжевая линия) на тестовом периоде. Модель продемонстрировала RMSE около 428.68, что заметно ниже результатов ряда других методов (например, Holt-Winters или SARIMA). Преимуществами линейной регрессии являются простота интерпретации (можно определить, какие факторы вносят наибольший вклад) и низкая вычислительная сложность. К недостаткам относится предположение о линейности взаимосвязей и необходимость ручного формирования признаков (если пропустить важные факторы, например, праздники, то точность снизится).

➤ Будем использовать daily\_total (Date, Visits).  
Linear Regression RMSE: 428.68




**Рис. 9. Прогноз трафика с линейной регрессией и календарными признаками**

Таким образом, линейная регрессия с календарными и лаговыми переменными способна довольно точно моделировать краткосрочную динамику веб-трафика, сохраняя при этом высокую интерпретируемость и скорость обучения. Для ещё более точных результатов можно применять One-Hot Encoding к `day_of_week` и `month`, добавлять дополнительные лаги (например, `lag7`) или переходить к более сложным алгоритмам (Random Forest, XGBoost), способным выявлять нелинейные зависимости.

В качестве дополнительного эксперимента были протестированы несколько популярных алгоритмов машинного обучения


и нейронных сетей (Fully Connected MLP, Decision Tree, Random Forest и GRU) для краткосрочного прогноза веб-трафика по «скользящему окну» длиной 7 дней, после чего предсказывалось значение на 8-й день.

На рис. 10 показан результат полносвязной нейронной сети (MLP) с RMSE около 471.62: модель достаточно хорошо повторяет краткосрочные колебания, однако при резких скачках (конец 2024 г. — начало 2025 г.) возникает заметное расхождение. MLP требует нормализации данных и тщательного подбора гиперпараметров, но при правильной настройке способна давать хорошие результаты.



**Рис. 10. Прогноз трафика Fully Connected MLP**


Рисунок 11 иллюстрирует работу Decision Tree (RMSE ~523.10), дающего «ступенчатые» прогнозы, типичные для деревьев. Модель легко интерпретировать и быстро обучать, но она склонна к переобучению и может хуже справляться с шумами.



**Рис. 11. Прогноз трафика (Decision Tree)**

На рис. 12 представлена Random Forest (RMSE  $\sim 425.85$ ), показавшая лучший результат среди деревьев за счёт усреднения предсказаний множества деревьев и лучшей адаптации к разнообразным паттернам. Модель сглаживает экстремальные значения и сохраняет часть интерпретируемости (можно смотреть важность признаков).

Используем `daily_total (Date, Visits)`.  
Random Forest – RMSE: 425.85




**Рис. 12. Прогноз трафика (Random Forest)**

Рисунок 13 демонстрирует прогноз GRU (Gated Recurrent Unit), близкой к LSTM рекуррентной сети. При RMSE  $\sim 538.23$  её результат оказался чуть хуже, чем у MLP и Random Forest. GRU хорошо улавливает краткосрочные зависимости, но нуждается в масштабировании данных, подборе числа слоёв и достаточном объёме обучающей выборки.

В целом GRU следует тренду, однако на пиковых участках возникают заметные ошибки.

Ниже приведена сравнительная таблица результатов эксперимента по всем методам (табл.).

GRU – RMSE: 538.23



**Рис. 13. Прогноз трафика (GRU)**

### Сравнение результатов прогнозирования веб-трафика

Метод	Описание	Основные параметры	Метрика	Значение ошибки прогноза
Random Forest	Ансамблевый метод (Random Forest) для регрессии	n_estimators=100, max_depth=10	RMSE	425,85
Линейная регрессия (с календарными признаками)	ML-модель с ручным формированием признаков (лаговые переменные и календарь)	day_of_week, month, day_of_year, lag1, lag2	RMSE	429
Fully Connected (MLP)	Полносвязная нейронная сеть (MLP) для прогнозирования временных рядов	Dense слой: 64, затем 32 нейрона; окно = 7 дней	RMSE	471,62
Decision Tree	Дерево решений для регрессии временного ряда	max_depth=10	RMSE	523,1
GRU	Рекуррентная нейросеть на базе GRU, аналог LSTM	2 слоя GRU (64 и 32 нейрона); окно = 7 дней	RMSE	538,23
SARIMA	ARIMA с учётом сезонности	SARIMA (1,1,1) (1,1,1,7); недельная сезонность	RMSE	964
Exponential Smoothing (Holt-Winters)	Эксп. Сглаживание с учетом тренда и сезонности	trend='add', seasonal='mul', seasonal_periods=7	RMSE	975
ARIMA	Классический статистический метод для стационарных рядов	ARIMA (1,1,1)	RMSE	1008
Prophet	Модель с декомпозицией на тренд и сезонности	yearly/daily_seasonality; интерпретируемая модель	—	(графический анализ)
LSTM	Рекуррентная нейросеть для нелинейных временных рядов	2 слоя (128, 64 нейронов); окно = 7 дней	MSE	0,0063 (на масштабированных данных)

## Выводы

В ходе исследования была проведена серия экспериментов по прогнозированию и классификации источников веб-трафика с применением как классических статистических моделей (ARIMA, SARIMA, Holt-Winters), так и современных алгоритмов машинного обучения и нейросетевых решений (Prophet, LSTM, GRU, Fully Connected, Decision Tree, Random Forest, линейная регрессия с календарными признаками).

Результаты исследования показали, что Random Forest даёт наименьшую ошибку прогноза, MLP превосходит GRU, Decision Tree является самым простым и интерпретируемым, а GRU остаётся перспективным вариантом при более глубокой настройке и расширении набора данных. Выбор метода зависит от приоритетов: интерпретируемости, скорости обучения или способности улавливать нелинейные паттерны.

Классические методы и модели (ARIMA, Holt-Winters) зачастую дают высокие значения ошибки из-за сглаживания резких колебаний и ограничений на стационарность; SARIMA с недельной сезонностью снижает ошибку, но по-прежнему не всегда учитывает аномальные всплески. Prophet хорошо интерпретирует тренды и сезонность, но может не отражать внезапные аномалии.

Нейросетевые подходы (LSTM, GRU, MLP) способны улавливать сложные нелинейные зависимости, однако требуют масштабирования данных и тщательного подбора гиперпараметров. Линейная регрессия с календарными и лаговыми признаками продемонстрировала небольшую ошибку (RMSE ~429), подчёркивая значение качественного выявления признаков, а ансамблевые методы (Random Forest) показали высокую точность за счёт усреднения предсказаний множества деревьев.

Выбор метода прогнозирования веб-трафика во многом зависит от специфики поставленной задачи: для общей оценки трендов подойдут ARIMA или Prophet, для более точного краткосрочного прогноза — нейросети или линейная регрессия с тщательно подобранными признаками. Возможно комбинировать несколько моделей, повышая надёжность и точность. Дальнейшие исследования могут включать расширение набора входных признаков (данные из CRM, рекламных кабинетов, социальных сетей), применение гибридных моделей и ансамблей для повышения стабильности, а также интеграцию методов объяснимости (SHAP, LIME) и анализ чувствительности гиперпараметров. Комплексный подход, сочетающий классические и современные нейросетевые подходы, даёт существенный прирост качества аналитики веб-трафика и помогает улучшать маркетинговые стратегии, распределение рекламного бюджета и управление ресурсами.

Теоретическая и практическая значимость исследования заключается в том, что оно позволило сравнить ряд методов про-

гнозирования веб-трафика и классификации источников трафика, среди которых использованы как классические статистические модели (ARIMA, SARIMA, Holt-Winters), так и современные методы машинного обучения и нейросетевые решения (Prophet, LSTM, GRU, Fully Connected, Decision Tree, Random Forest, линейная регрессия с календарными признаками), даны рекомендации по их применению. На основании исследования в дальнейшем будет разработана методика и цифровой сервис по прогнозированию веб-трафика и распределению рекламного бюджета.

### References

1. Chaffey D., Patron M. From Web Analytics to Digital Marketing Optimization: Increasing the Commercial Value of Digital Analytics. *Journal of Direct, Data and Digital Marketing Practice*, 2012, no. 14(1), pp. 30–45.
2. Ghahramani Z. Probabilistic Machine Learning and Artificial Intelligence. *Nature*, 2015, no. 521(7553), pp. 452–459.
3. Zhang Z., Zhang J., Li Z. Hybrid LSTM-SOM Network for Anomaly Detection in Web Traffic. *Procedia Computer Science*, 2020, no. 169, pp. 66–72.
4. Borges J., Levene M. A Dynamic Clustering-Based Markov Model for Web Usage Mining. *Journal of Intelligent Information Systems*, 2007, no. 29, pp. 295–319.
5. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. *Time Series Analysis: Forecasting and Control*. 5<sup>th</sup> ed. Wiley, 2015. 720 p.
6. Hyndman R.J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3<sup>rd</sup> ed. OTexts, 2021. 442 p.
7. Taylor S.J., Letham B. Forecasting at Scale. *The American Statistician*, 2018, no. 72(1), pp. 37–45.

### Информация об авторах

**Архипова Зоя Валентиновна** — кандидат экономических наук, доцент, кафедра математических методов и цифровых технологий, Байкальский государственный университет, г. Иркутск, Российская Федерация, e-mail: zvarhipova@yandex.ru.

**Федькина Дарья Дмитриевна** — магистрант, кафедра математических методов и цифровых технологий, Байкальский государственный университет, г. Иркутск, Российская Федерация, e-mail: shkilyaeva\_darya@mail.ru.

### Information about the Authors

**Zoya V. Arkhipova** — PhD in Economics, Associate Professor, Department of Mathematical Methods and Digital Technologies, Baikal State University, Irkutsk, Russian Federation, e-mail: zvarhipova@yandex.ru.

**Darya D. Fedkina** — Master's Degree Student, Department of Mathematical Methods and Digital Technologies, Baikal State University, Irkutsk, Russian Federation, e-mail: shkilyaeva\_darya@mail.ru.

### Вклад авторов

Все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

### Contribution of the Authors

The authors contributed equally to this article. The authors declare no conflicts of interests.



**Для цитирования**

Архипова З.В. Современные подходы к выбору метода анализа и прогнозирования веб-трафика в интернет-маркетинге / З.В. Архипова, Д.Д. Федькина. — DOI 10.17150/2713-1734.2025.7(2).178-193. — EDN PECBZZ // System Analysis & Mathematical Modeling. — 2025. — Т. 7, № 2. — С. 178–193.

**For Citation**

Arkhipova Z.V., Fedkina D.D. Modern Approaches to Choosing a Method of Analyzing and Forecasting Web Traffic in Internet Marketing. *System Analysis & Mathematical Modeling*, 2025, vol. 7, no. 2, pp. 178–193. (In Russian). EDN: PECBZZ. DOI: 10.17150/2713-1734.2025.7(2).178-193.