Сравнительная оценка методов прогнозирования оборота предприятий электронной коммерции

Соколов Никита Валерьевич
аспирант, базовая кафедра цифровой экономики института развития информационного общества, РЭУ им. Г.В. Плеханова, twinvlr@yandex.ru

В статье представлена сравнительная оценка методов статистического прогнозирования и машинного обучения при прогнозировании оборота предприятия электронной коммерции. На временном ряде месячного оборота компании E-commerce за период с января 2023 г. по июнь 2026 г. (42 наблюдения) сопоставлены четыре модели: Holt-Winters, SARIMA, LightGBM и XGBoost. Обучение выполнено на 36 месяцах, тестирование – на 6 наблюдениях с соблюдением хронологического порядка. Качество прогнозов оценивалось с использованием MAE, RMSE, MAPE и sMAPE, при этом MAE и RMSE дополнительно нормировались относительно среднего значения оборота тестовой выборки. Наилучший результат по всем метрикам показал LightGBM (MAPE – 6,37%), при этом Holt-Winters обеспечил сопоставимую точность (MAPE – 7,32%). Результаты свидетельствуют, что применение более сложного алгоритма не гарантирует существенного повышения точности, а выбор модели целесообразно проводить на основе эмпирической проверки на данных конкретного предприятия с учётом интерпретируемости и трудоёмкости сопровождения.

Ключевые слова: электронная коммерция, прогнозирование оборота, временные ряды, экспоненциальное сглаживание, SARIMA, градиентный бустинг, LightGBM, XGBoost.

Введение

Развитие электронной коммерции сопровождается постоянным увеличением объёма данных о продажах, заказах и поведении покупателей. Эти данные используются не только для анализа уже достигнутых результатов, но и для планирования дальнейшей деятельности предприятий. Одной из востребованных задач в данном направлении является прогнозирование показателей продаж и оборота, поскольку качество прогнозных оценок может использоваться при планировании закупок, управлении запасами, распределении ресурсов и формировании маркетинговой активности. В исследованиях по прогнозированию розничных продаж отмечается, что особенности таких данных связаны с наличием трендов, сезонности, календарных эффектов и воздействием различных внешних факторов, что делает выбор подходящего метода отдельной исследовательской задачей [1; 2].

Для решения задач прогнозирования применяются как статистические методы анализа временных рядов, так и алгоритмы машинного обучения. Классические подходы, основанные на экспоненциальном сглаживании и авторегрессионных моделях, позволяют описывать зависимость текущих значений показателя от его предыдущей динамики. Их преимуществом является относительная простота и возможность интерпретации получаемых результатов. Вместе с тем при наличии нелинейных зависимостей и большого числа факторов, влияющих на прогнозируемый показатель, возможности традиционных моделей могут оказаться ограниченными. В российской научной литературе также рассматривается совместное применение статистических методов и методов машинного обучения для анализа временных рядов и повышения качества прогнозов деятельности предприятий [3].

В последние годы особое внимание уделяется эмпирическому сравнению различных методов. Зачастую сам факт применения более сложного алгоритма не означает, что он будет обеспечивать более точный прогноз для конкретного временного ряда. Результат зависит от объёма и структуры исходных данных, характера временной зависимости, наличия сезонности и других особенностей исследуемого показателя. В частности, исследования в области розничного прогнозирования показывают, что результаты статистических и машинных методов могут существенно различаться в зависимости от постановки задачи и доступной информационной базы [2].

Для электронной коммерции данный вопрос имеет дополнительное значение. Продажи формируются под воздействием большого количества факторов, а изменение структуры спроса может происходить достаточно быстро. В зарубежных исследованиях для прогнозирования онлайн-продаж рассматриваются методы, способные учитывать сложную динамику временных рядов и несколько одновременно действующих тенденций. Например, при прогнозировании продаж товаров электронной коммерции используются вероятностные модели, позволяющие учитывать тренды, сезонность и дополнительные характеристики процесса продаж [3].

В связи с этим представляет интерес проведение непосредственного сравнительного эксперимента, в рамках которого различные классы прогнозных моделей оцениваются на одной и той же временной последовательности и по единым критериям. Такой подход позволяет отделить особенности конкретного алгоритма от влияния различий в исходных данных или процедуре оценки и определить, насколько применение более сложного метода действительно связано с повышением качества прогноза.

Целью исследования является сравнительная оценка методов статистического прогнозирования и машинного обучения при прогнозировании оборота предприятия электронной коммерции.

Научная новизна исследования заключается в сравнительной оценке прогнозных моделей различных классов на единой временной последовательности показателя оборота предприятия электронной коммерции с использованием единого подхода к формированию выборок и оценке качества прогнозирования. Практическая значимость работы состоит в возможности использования полученных результатов при выборе прогнозного инструментария для решения задач планирования и аналитического сопровождения деятельности предприятий электронной коммерции.

Оборот предприятий электронной коммерции как объект прогнозирования

В условиях цифровизации торговли показатели продаж и оборота становятся важным элементом информационного обеспечения текущего и перспективного управления предприятием. Для организаций электронной коммерции это особенно характерно вследствие большого объёма данных, формируемых в процессе взаимодействия покупателей с цифровыми каналами продаж. Источниками информации выступают данные о заказах, оплатах, ассортименте, ценах, рекламной активности, посещаемости интернет-ресурсов и других характеристиках поведения покупателей. Наличие такой информационной базы создаёт условия для перехода от

анализа уже достигнутых результатов к количественной оценке будущей динамики.

Электронная коммерция при этом представляет собой не только отдельный канал реализации товаров, но и информационно насыщенную среду осуществления хозяйственной деятельности. В современных исследованиях электронного бизнеса подчёркивается значение цифровых информационных технологий для организации взаимодействия экономических субъектов и обработки данных, необходимых для управленческих решений. В частности, А. И. Уринцов рассматривает электронный обмен данными как инструмент решения экономических и управленческих задач, связывая его с интеграцией информационных потоков и стандартизацией обмена данными [5]. Современное понимание информационного обеспечения управления предполагает, что накопленные данные должны использоваться не только для фиксации текущего состояния предприятия, но и для формирования аналитической основы последующих решений.

В данном контексте оборот предприятия может рассматриваться как один из ключевых агрегированных показателей его коммерческой деятельности. При последовательном наблюдении через равные промежутки времени значения оборота образуют временной ряд:

$Y = \{y_1,\ y_2, \dots ,\ y_t, \dots ,\ y_n\}$, где

y_t – значение оборота в периоде t,

n – количество наблюдений.

Особенность временного ряда заключается в том, что порядок наблюдений имеет принципиальное значение. Значение оборота в текущем периоде может быть связано с результатами предыдущих периодов, а характер этой зависимости способен изменяться во времени. Поэтому задача прогнозирования заключается не просто в установлении зависимости между набором независимых признаков и целевой переменной, а в оценке будущего состояния экономического показателя с использованием информации, доступной до момента формирования прогноза.

Для показателей продаж характерно наличие нескольких источников вариации. К ним могут относиться долгосрочная тенденция изменения оборота, сезонные колебания, календарные эффекты, изменение цен и ассортимента, маркетинговая активность и другие факторы. Масштабное исследование M5, проведённое на реальных данных розничных продаж Walmart, показало, что современные задачи прогнозирования продаж могут включать одновременно большое количество взаимосвязанных временных рядов, календарные признаки, цены и сведения о специальных событиях [6].

Вопрос выбора метода прогнозирования должен решаться применительно к характеристикам конкретного временного. В систематическом исследовании методов прогнозирования продаж, отмечается существенное увеличение числа работ, использующих машинное обучение и глубокое обучение. Вместе с тем авторы указывают на зависимость качества прогнозирования от структуры рынка, объёма доступных данных и характеристик конкретной задачи [7].

Таким образом, оборот предприятия электронной коммерции может быть представлен как экономический временной ряд, характеристики которого определяют требования к используемому прогнозному инструментарию. Для его исследования целесообразно рассматривать одновременно статистические методы, ориентированные преимущественно на закономерности самого временного ряда, и алгоритмы машинного обучения, способные учитывать более широкий набор признаков.

Методы и методика сравнительного исследования

Современные методы прогнозирования продаж можно условно разделить на несколько групп: статистические модели временных рядов, алгоритмы машинного обучения, методы глубокого обучения и различные гибридные подходы. Анализ современной литературы показывает, что развитие прогнозной аналитики происходит не столько за счёт полного отказа от традиционных моделей, сколько за счёт расширения набора доступных методов и их последующего эмпирического сопоставления [7].

Статистические модели сохраняют практическое значение благодаря относительно небольшому количеству параметров, интерпретируемости и возможности получения прогноза непосредственно на основе исторической последовательности наблюдений. К данной группе относятся модели экспоненциального сглаживания, авторегрессионные модели и различные варианты ARIMA. Их общей особенностью является представление будущего значения через структуру предыдущих наблюдений и случайной составляющей.

Методы экспоненциального сглаживания позволяют учитывать уровень временного ряда, тренд и сезонные колебания. Их применение особенно целесообразно в случаях, когда наблюдаемая динамика относительно стабильна и не требуется использование большого числа внешних факторов. Результаты M5 показывают, что даже в условиях современной высокоразмерной задачи розничного прогнозирования относительно простые методы экспоненциального сглаживания способны оставаться конкурентоспособными для отдельных типов временных рядов [6].

Авторегрессионные модели, напротив, делают акцент на зависимости текущего значения от предыдущих значений ряда. Для экономических показателей применяются, в частности, модели ARIMA и SARIMA, позволяющие учитывать нестационарность и сезонную структуру. Их преимуществом является наличие развитого математического аппарата диагностики и интерпретации параметров. Однако эффективность таких моделей может снижаться при существенной нелинейности зависимостей или при наличии большого числа внешних факторов.

Отдельное место среди современных инструментов занимает модель Prophet, ориентированная на прогнозирование бизнес-временных рядов. В её основе лежит представление временного ряда как комбинации тренда, сезонных компонентов, календарных эффектов и случайной составляющей. В прикладных исследованиях розничных продаж Prophet часто рассматривается наряду с Holt–Winters и сезонными ARIMA как один из базовых методов сравнения. Российское исследование 2024 г., посвящённое сравнительной оценке моделей прогнозирования продаж в розничной торговле, также рассматривает Holt–Winters, Prophet и сезонную ARIMA и использует MAE, MSE и MAPE для оценки качества прогнозов.

При переходе к машинному обучению меняется принцип формирования прогнозной модели. Алгоритм обучается на наборе признаков, среди которых могут использоваться лаговые значения целевого показателя, календарные признаки, скользящие статистики и различные внешние характеристики. В результате временная зависимость представляется не только как последовательность значений, но и как набор признаков, позволяющий алгоритму выявлять нелинейные зависимости.

Для прогнозирования оборота предприятия перспективными являются прежде всего алгоритмы на основе ансамблей деревьев решений, включая градиентный бустинг. Такие модели позволяют учитывать нелинейные зависимости между лаговыми признаками, календарными характеристиками и внешними факторами. При этом их применение требует дополнительного этапа формирования признаков. Например, для прогноза оборота на месяц t+1 могут использоваться значения оборота за предыдущие периоды:

$X_t = (Y_t, Y_{t-1}, \dots, Y_{t-k})$, где

k – количество используемых временных лагов.

Дополнительно в X_t могут включаться признаки месяца, квартала, сезонности, праздничных периодов и другие характеристики. Принципиальным условием является отсутствие в признаках информации, которая становится известной только после наступления прогнозируемого периода. Интересные результаты в этом отношении получены при исследовании методов прогнозирования розничных продаж с объясняющими переменными. В работе Wellens, Boute и Udenio, опубликованной в European Journal of Operational Research в 2024 г., показано, что относительно простой подход на основе деревьев решений может демонстрировать высокую точность при наличии качественных объясняющих признаков, тогда как дальнейшее усложнение архитектуры модели даёт сравнительно небольшой дополнительный эффект [8].

При подготовке к формированию прогноза по данным целесообразно оценить несколько доступных методов на едином наборе данных и с использованием одинаковой процедуры проверки. В частности, в рамках M5 Competition сравнивались десятки подходов на единой базе реальных розничных продаж, что позволило получить эмпирические данные о соотношении статистических и машинных методов [6]. При этом результаты соревнования показали, что машинное обучение может обеспечивать существенные улучшения на сложных многомерных задачах, но статистические методы остаются конкурентоспособными в ряде отдельных сценариев [6].

Для временного ряда оборота особенно важно соблюдать хронологический порядок наблюдений. Обучающая выборка должна содержать только значения, предшествующие прогнозируемому периоду, а тестовая выборка – последующие наблюдения. Случайное перемешивание наблюдений в такой ситуации может привести к утечке информации из будущего и, следовательно, к завышенной оценке качества модели.

Кроме того, при сравнении моделей необходимо использовать единый прогнозный горизонт. Если одна модель оценивается на ближайшем месяце, а другая – на нескольких периодах, полученные показатели ошибки нельзя считать непосредственно сопоставимыми. Поэтому в рамках экспериментальной части настоящей работы предполагается использование одинакового тестового периода для всех рассматриваемых моделей.

Для количественной оценки точности прогнозов целесообразно использовать несколько метрик. В исследованиях прогнозирования розничных продаж применяются, в частности, MAE, RMSE и MAPE [9].

Средняя абсолютная ошибка определяется выражением:

$MAE = \frac{1}{n}\sum_{t=1}^{n}|Y_t - Z_t|$, где

Y_t– фактическое значение оборота,

Z_t– прогнозное значение оборота,

n – число наблюдений тестовой выборки.

Среднеквадратичная ошибка рассчитывается следующим образом:

$$RMSE = \sqrt{\frac{1}{n}\sum_{t=1}^{n}(Y_t - Z_t)^2}$$

В отличие от MAE, данная метрика сильнее реагирует на отдельные крупные отклонения. Поэтому её использование особенно полезно при анализе оборота, если ошибки в периоды резкого изменения продаж имеют повышенное экономическое значение.

Для относительной оценки используется средняя абсолютная процентная ошибка:

$$MAPE = \frac{100\%}{n}\sum_{t=1}^{n}\left|\frac{Y_t - Z_t}{Y_t}\right|$$

Использование нескольких метрик позволяет получить более полную характеристику качества прогнозирования. В то же время выбор метрики должен соответствовать особенностям данных. В современных исследованиях прогнозирования продаж отмечается необходимость учитывать не только точность отдельных прогнозов, но и практические последствия ошибок для управленческих решений [6].

Для проведения сравнительной оценки методов прогнозирования был сформирован временной ряд месячного оборота предприятия электронной коммерции за период с января 2023 г. по июнь 2026 г. Таким образом, исходная выборка включала 42 последовательных наблюдения. При формировании экспериментальной выборки соблюдался принцип сохранения временной последовательности данных, поскольку случайное разделение наблюдений на обучающую и тестовую выборки для задач прогнозирования временных рядов может приводить к использованию информации из будущего при построении модели.

С целью оценки способности моделей прогнозировать значения, не использованные непосредственно при их обучении, временной ряд был разделён на обучающую и тестовую части. В обучающую выборку вошли наблюдения за период с января 2023 г. по декабрь 2025 г. – 36 месяцев. Тестовая выборка включала период с января по июнь 2026 г., то есть последние шесть фактических наблюдений. Такой подход позволил оценить качество прогноза на временном интервале, расположенном непосредственно после окончания обучающего периода.

В исследовании рассматривались четыре модели, относящиеся к различным классам методов прогнозирования: модель экспоненциального сглаживания Holt–Winters, сезонная авторегрессионная модель SARIMA, алгоритм градиентного бустинга LightGBM и алгоритм XGBoost. Выбор моделей обусловлен необходимостью сопоставить традиционные статистические методы с современными алгоритмами машинного обучения.

Модель Holt–Winters использовалась для учёта одновременно наблюдаемых трендовой и сезонной составляющих временного ряда. При этом для месячных данных в модели задавался сезонный период, равный 12 месяцам. Данный подход позволяет учитывать повторяющиеся внутригодовые изменения оборота и одновременно моделировать его долгосрочное изменение.

SARIMA относится к классу авторегрессионных моделей, объединяющих авторегрессионную составляющую, скользящее среднее и процедуры дифференцирования. Включение сезонной компоненты позволяет учитывать зависимость текущих значений оборота от наблюдений соответствующих месяцев предыдущих периодов.

В качестве представителей методов машинного обучения использовались LightGBM и XGBoost. В отличие от статистических моделей, данные алгоритмы рассматривали прогнозирование как задачу регрессии на основе сформированных признаков временного ряда. В качестве входной информации использовались лаговые значения показателя, характеристики скользящей динамики и календарные признаки. Такой подход позволяет алгоритмам градиентного бустинга учитывать нелинейные зависимости между текущим значением оборота и его предшествующей динамикой.

Для количественной оценки точности прогнозов использовались средняя абсолютная ошибка (MAE), корень из среднеквадратичной ошибки (RMSE), средняя абсолютная процентная ошибка (MAPE) и симметричная средняя абсолютная процентная ошибка (sMAPE). Использование нескольких критериев позволяет избежать зависимости результатов сравнения от одной характеристики ошибки.

Поскольку абсолютные значения оборота относятся к внутренним данным предприятия и не подлежат раскрытию, при представлении результатов использовались относительные показатели ошибок. Нормированная средняя абсолютная ошибка рассчитывалась как отношение MAE к среднему значению оборота в тестовой выборке:

$$MAE_{norm} = \frac{MAE}{y} \times 100\%, \text{где}$$

MAE – средняя абсолютная ошибка прогноза;

y – среднее фактическое значение показателя в тестовом периоде.

Такой способ представления результатов позволяет сохранить возможность сопоставления моделей без раскрытия коммерчески чувствительных абсолютных значений оборота.

Важной особенностью исследования является единый порядок формирования обучающей и тестовой выборок и одинаковый прогнозный горизонт для всех рассматриваемых методов. Это позволяет интерпретировать различия в значениях метрик преимущественно как результат различий в свойствах самих моделей, а не как следствие различной процедуры их проверки.

Результаты прогнозирования

По результатам проведённого эксперимента были получены прогнозные значения оборота на период с января по июнь 2026 г. Для каждой модели рассчитаны значения MAE, RMSE, MAPE и sMAPE. С учётом требований к конфиденциальности исходной информации абсолютные значения оборота и абсолютные величины ошибок в исследовании не приводятся.

Результаты сравнительной оценки представлены в таблице 1.

Таблица 1

Сравнительная оценка точности методов прогнозирования оборота предприятия электронной коммерции

Модель	Нормированная MAE, %	Нормированная RMSE, %	MAPE, %	sMAPE, %
Holt-Winters	6,76	8,78	7,32	6,88
SARIMA	9,53	12,13	10,09	9,29
LightGBM	6,03	7,05	6,37	6,19
XGBoost	10,14	11,52	10,80	10,07

Источник: рассчитано автором.

Представленные результаты показывают, что на рассматриваемом временном ряду наиболее низкие значения ошибок были получены при использовании LightGBM. Нормированная средняя абсолютная ошибка данной модели составила 6,03%, RMSE – 7,05%, MAPE – 6,37%, а sMAPE – 6,19%. Таким образом, по всем четырём рассматриваемым критериям модель LightGBM продемонстрировала наиболее низкие значения ошибок среди исследуемых методов.

Ближайший результат был получен для модели Holt–Winters. Значение MAPE для неё составило 7,32%, что примерно на 0,95 процентного пункта выше результата LightGBM. Аналогичная тенденция наблюдается по нормированной MAE и sMAPE. При этом различие между двумя моделями нельзя считать настолько значительным, чтобы делать вывод о принципиально ином характере прогнозирования: обе модели обеспечили относительно близкие результаты на рассматриваемом временном ряду.

Более существенные различия наблюдаются при сравнении LightGBM с SARIMA и XGBoost. Значение MAPE для SARIMA составило 10,09%, а для XGBoost – 10,80%. Значения RMSE также оказались выше, чем у двух других моделей. Это свидетельствует о наличии более крупных прогнозных отклонений на отдельных наблюдениях тестового периода.

Среди статистических методов более низкие значения ошибок были получены у Holt–Winters. Его преимущество относительно SARIMA проявляется по всем использованным критериям. В частности, MAPE Holt–Winters составила 7,32%, тогда как у SARIMA данный показатель достиг 10,09%. Аналогичная картина наблюдается для RMSE: 8,78% против 12,13%.

При этом SARIMA показала более высокую величину ошибки. Одной из возможных причин является ограниченный объём обучающей выборки. После выделения тестового периода для оценки модели использовалось 36 месячных наблюдений. Для сложной сезонной авторегрессионной структуры это относительно небольшой объём данных, вследствие чего оценка большого количества параметров может быть менее устойчивой.

Результаты моделей машинного обучения оказались неоднородными. LightGBM продемонстрировал наиболее низкие значения всех четырёх рассматриваемых метрик. В то же время XGBoost показал наибольшую MAPE среди исследуемых моделей – 10,80%.

Таким образом, сам факт применения алгоритма градиентного бустинга не гарантировал повышения точности. Различия между LightGBM и XGBoost показывают, что принадлежность моделей к одному классу алгоритмов не означает одинаковой способности описывать конкретную временную зависимость. На качество прогноза влияет не только используемый алгоритм, но и объём доступной выборки, структура признаков, параметры обучения и характер самого временного ряда.

Полученный вывод соответствует результатам современных исследований в области прогнозирования розничных продаж. В частности, в M5 Competition высокая точность LightGBM была связана не только с алгоритмом как таковым, но и с возможностью использовать большое количество взаимосвязанных рядов и дополнительных объясняющих переменных. Исследование Wellens, Boute и Udenio также показывает, что преимущество tree-based моделей зависит от доступности дополнительных данных и качества инженерии признаков, тогда как дальнейшее усложнение алгоритма может давать лишь ограниченный прирост точности.

Следовательно, результаты проведённого эксперимента позволяют рассматривать выбор модели как самостоятельную аналитическую задачу, которая должна основываться на эмпирической проверке нескольких альтернативных методов.

Выводы

Полученный результат, проведенного исследования, показывает целесообразность проведения сравнительного тестирования перед внедрением прогнозной модели в аналитическую практику. Исследования в области прогнозирования продаж указывают на отсутствие универсального метода, обеспечивающего минимальную ошибку для любых временных рядов. В частности, результаты крупных forecasting competitions демонстрируют эффективность ML-подходов, но одновременно подтверждают необходимость сопоставления их с классическими статистическими методами.

Стоит также отметить, что проведенное исследование имеет ограничения, связанные с объемом данных. Полученные результаты характеризуют качество моделей применительно к исследуемому ряду и не позволяют распространить выявленные соотношения между методами на все предприятия

электронной коммерции. Для дальнейших исследований целесообразно расширить временной горизонт, использовать несколько предприятий или товарных категорий, а также оценить устойчивость результатов при изменении прогнозного горизонта и состава входных признаков.

Таким образом, выбор метода прогнозирования оборота предприятия электронной коммерции целесообразно осуществлять не только исходя из технологической сложности алгоритма, но и на основе фактически достигнутого качества прогнозирования на данных конкретного предприятия. Для исследуемого временного ряда результаты эксперимента свидетельствуют о возможности применения как LightGBM, так и более простого статистического подхода Holt–Winters, при этом окончательный выбор между ними должен учитывать не только точность, но и требования к интерпретируемости, трудоёмкости сопровождения и доступности дополнительных данных.

Литература

1. Policarpo L.M., da Silveira D.E., Righi R.R. et al. Machine learning through the lens of e-commerce initiatives: An up-to-date systematic literature review // Computer Science Review. 2021. Vol. 41. 100414. DOI: 10.1016/j.cosrev.2021.100414 EDN: KCSIAX
2. Zhang X., Guo F., Chen T., Pan L., Beliakov G., Wu J. Journal of Theoretical and Applied Electronic Commerce Research, 2023, Vol. 18, No. 4, pp. 2188–2216, DOI 10.3390/jtaer18040110. DOI: 10.3390/jtaer18040110 EDN: GDEYRH
3. Du C., Li Y. E-commerce sales forecasting based on deep learning algorithm // Procedia Computer Science. 2025. Vol. 261. P. 1157–1164. DOI: 10.1016/j.procs.2025.04.699. DOI: 10.1016/j.procs.2025.04.699 EDN: ALIANJ
4. Патраков П.А. Использование методов прогнозирования временных рядов для оптимизации деятельности предприятий // Вестник науки. 2025. EDN: RVVXQN
5. Уринцов А. И. Электронный обмен данными : учебное пособие / А. И. Уринцов. – Москва : ЕАОИ, 2024. – 184 с. – ISBN 978-5-374-00463-2. ISBN: 978-5-374-00463-2
6. Makridakis S., Spiliotis E., Assimakopoulos V. M5 accuracy competition: Results, findings, and conclusions // International Journal of Forecasting. – 2022. – Vol. 38, № 4. – P. 1346–1364. – DOI: 10.1016/j.ijforecast.2021.11.013. https://doi.org/10.1016/j.ijforecast.2021.11.013
7. Ahaggach H., Abrouk L., Lebon E. Systematic Mapping Study of Sales Forecasting: Methods, Trends, and Future Directions // Forecasting. 2024. Vol. 6, No. 3. P. 502–532. DOI: 10.3390/forecast6030028. DOI: 10.3390/forecast6030028 EDN: QRVIYS
8. Wellens A. P., Boute R. N., Udenio M. Simplifying tree-based methods for retail sales forecasting with explanatory variables // European Journal of Operational Research. – 2024. – Vol. 314, № 2. – P. 523–539. DOI: 10.1016/j.ejor.2023.10.039 DOI: 10.1016/j.ejor.2023.10.039 EDN: WGTYSA
9. Applying Machine Learning in Retail Demand Prediction—A Comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning // Applied Sciences. – 2023. – Vol. 13, № 19. – 11112. – DOI: 10.3390/app131911112. DOI: 10.3390/app131911112 EDN: UPUOEC

Comparative assessment of forecasting methods for the turnover of e-commerce enterprises

Sokolov N.V.
Plekhanov Russian University of Economics

JEL classification: C01, C02, C1, C4, C5, C6, C8

The article presents a comparative assessment of statistical forecasting and machine learning methods for predicting the turnover of an e-commerce enterprise. Four models are compared using a time series of the monthly turnover of an E-commerce company for the period from January 2023 to June 2026 (42 observations): Holt-Winters, SARIMA, LightGBM, and XGBoost. Training was performed on 36 months, and testing was carried out on 6 observations, maintaining chronological order. The quality of the forecasts was assessed using normalized indicators MAE, RMSE, MAPE, and sMAPE. LightGBM showed the lowest error across all metrics (MAPE – 6.37%), while Holt-Winters demonstrated comparable accuracy (MAPE – 7.32%). The results indicate that using a more complex algorithm does not guarantee a significant increase in accuracy, and it is advisable to select a model based on empirical testing using data from a specific enterprise, taking into account interpretability and the effort required for maintenance.

Keywords: e-commerce, turnover forecasting, time series, exponential smoothing, SARIMA, gradient boosting, LightGBM, XGBoost.

References

1. Policarpo L.M., da Silveira D.E., Righi R.R. et al. Machine learning through the lens of e-commerce initiatives: An up-to-date systematic literature review // Computer Science Review. 2021. Vol. 41. 100414. DOI: 10.1016/j.cosrev.2021.100414 EDN: KCSIAX
2. Zhang X., Guo F., Chen T., Pan L., Beliakov G., Wu J. Journal of Theoretical and Applied Electronic Commerce Research, 2023, Vol. 18, No. 4, pp. 2188–2216, DOI 10.3390/jtaer18040110. DOI: 10.3390/jtaer18040110 EDN: GDEYRH
3. Du C., Li Y. E-commerce sales forecasting based on deep learning algorithm // Procedia Computer Science. 2025. Vol. 261. P. 1157–1164. DOI: 10.1016/j.procs.2025.04.699. DOI: 10.1016/j.procs.2025.04.699 EDN: ALIANJ
4. Patrakov P.A. Using time series forecasting methods to optimize enterprise operations // Vestnik Nauki (Bulletin of Science). 2025. EDN: RVVXQN
5. Urintsov A.I. Electronic Data Interchange: A Textbook / A.I. Urintsov. – Moscow: EAOI, 2024. – 184 p. – ISBN 978-5-374-00463-2. ISBN: 978-5-374-00463-2
6. Makridakis S., Spiliotis E., Assimakopoulos V. M5 accuracy competition: Results, findings, and conclusions // International Journal of Forecasting. – 2022. – Vol. 38, No. 4. – P. 1346–1364. – DOI: 10.1016/j.ijforecast.2021.11.013. https://doi.org/10.1016/j.ijforecast.2021.11.013
7. Ahaggach H., Abrouk L., Lebon E. Systematic Mapping Study of Sales Forecasting: Methods, Trends, and Future Directions // Forecasting. 2024. Vol. 6, No. 3. P. 502–532. DOI: 10.3390/forecast6030028. DOI: 10.3390/forecast6030028 EDN: QRVIYS
8. Wellens A. P., Boute R. N., Udenio M. Simplifying tree-based methods for retail sales forecasting with explanatory variables // European Journal of Operational Research. – 2024. – Vol. 314, No. 2. – P. 523–539. DOI: 10.1016/j.ejor.2023.10.039 DOI: 10.1016/j.ejor.2023.10.039 EDN: WGTYSA
9. Applying Machine Learning in Retail Demand Prediction—A Comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning // Applied Sciences. – 2023. – Vol. 13, No. 19. – 11112. – DOI: 10.3390/app131911112. DOI: 10.3390/app131911112 EDN: UPUOEC