

МАРКЕТИНГ И ПОТРЕБИТЕЛЬСКОЕ ПОВЕДЕНИЕ

MARKETING AND CONSUMER BEHAVIOR

DOI: 10.12731/3033-5973-2025-14-4-325

EDN: DHNKGU

УДК 339.138:339.37:004.85



Научная статья

**РАСШИРЕННАЯ АНАЛИТИКА
КАК ИНСТРУМЕНТ ЭФФЕКТИВНОГО
ТРЕЙД-МАРКЕТИНГА В РИТЕЙЛЕ***Т.И. Сахнюк, М.В. Коршикова, П.А. Сахнюк***Аннотация**

Обоснование. В мире высокой конкуренцией на рынке табачной продукции, компании сталкиваются с необходимостью оптимизации процессов анализа данных и принятия решений. Основной проблемой является обработка постоянно растущих объемов данных о продажах, которые ранее хранились и анализировались в Excel, что приводило к замедлению процессов анализа, ошибкам в расчетах и снижению эффективности маркетинговых стратегий. Для решения этой проблемы руководством компании было принято решение перейти на использование современных технологий.

Актуальность обусловлена высокой конкуренцией на рынке табачной продукции и необходимостью оптимизации процессов анализа данных и принятия решений. Ранее данные о продажах хранились и анализировались в Excel, что приводило к замедлению анализа, ошибкам в расчётах и снижению эффективности маркетинговых стратегий.

Цель – разработка и внедрение системы анализа данных и прогнозирования продаж на основе машинного обучения для повышения эффективности трейд-маркетинга.

Метод и методология проведения работы. В работе применяются методы машинного обучения, автоматизация аналитической отчётности, а также инструменты для работы с данными (PostgreSQL, Power BI, Python). Для управления выполнением скриптов обработки данных и обучения моделей, контроля обновления аналитических отчётов и интеграции системы с CRM используется Airflow.

Результаты. Разработана система обработки и анализа данных; осуществлён перенос данных из Excel в PostgreSQL с решением проблем кодировки; реализованы механизмы автоматической загрузки и конвертации данных, проведена качественная подготовка данных для анализа.

Область применения результатов. Результаты исследования могут быть применены в компании, работающие с большими объёмами данных; сфере бизнес-аналитики и работы с большими данными; отрасли с жёсткой конкуренцией и сложными рыночными условиями.

Ключевые слова: трейд-маркетинг; машинное обучение; прогнозирование продаж; большие данные; бизнес-аналитика; PostgreSQL; Power BI; Python; XGBoost

Для цитирования. Сахнюк, Т. И., Коршикова, М. В., & Сахнюк, П. А. (2025). Расширенная аналитика как инструмент эффективного трейд-маркетинга в ритейле. *Siberian Journal of Economic and Business Studies / Сибирский журнал экономических и бизнес-исследований*, 14(4), 214–228. <https://doi.org/10.12731/3033-5973-2025-14-4-325>

Original article

ADVANCED ANALYTICS AS A TOOL FOR EFFECTIVE TRADE MARKETING IN RETAIL

T.I. Sakhnyuk, M.V. Korshikova, P.A. Sakhnyuk

Abstract

Background. In a highly competitive world in the tobacco market, companies face the need to optimize their data analysis and decision-making processes. The main problem is the processing of ever-growing volumes of sales data that were previously stored and analyzed in Excel, which led to slower analysis processes, calculation errors, and reduced effectiveness of marketing strategies. To solve this problem, the company's management decided to switch to using modern technologies.

The relevance of the study is due to high competition in the tobacco market and the need to optimize data analysis and decision-making processes. Previously, sales data was stored and analyzed in Excel, which slowed down analysis, led to calculation errors, and reduced the effectiveness of marketing strategies.

Purpose: to develop and implement a machine learning-based data analysis and sales forecasting system to improve the effectiveness of trade marketing

Methodology. The work uses machine learning methods, automation of analytical reporting, as well as tools for working with data (PostgreSQL, Power BI, Python). Airflow is used to manage the execution of data processing scripts and model training, monitor the updating of analytical reports, and integrate the system with CRM.

Results. A data processing and analysis system has been developed; data has been transferred from Excel to PostgreSQL to solve encoding problems; automatic data loading and conversion mechanisms have been implemented; high-quality data preparation for analysis has been carried out.

Practical implications. The results of the study can be applied in companies working with large volumes of data; in the field of business analytics and working with big data; in industries with fierce competition and complex market conditions.

Keywords: trade marketing; machine learning; sales forecasting; big data; business analytics; PostgreSQL; Power BI; Python; XGBoost

For citation. Sakhnyuk, T. I., Korshikova, M. V., & Sakhnyuk, P. A. (2025). Advanced analytics as a tool for effective trade marketing in retail. *Siberian Journal of Economic and Business Studies*, 14(4), 214–228. <https://doi.org/10.12731/3033-5973-2025-14-4-325>

В современном мире трейд-маркетинг представляет собой стратегически важное направление маркетинговой деятельности, ориентированное на построение эффективных отношений с торговыми посредниками. Основными инструментами трейд-маркетинга являются мерчандайзинг, трейд-промоушн и кооперативный маркетинг. Трейд-маркетинг требует комплексного аналитического подхода для достижения максимальной эффективности.

Машинное обучение открыло новые возможности для автоматизации аналитических процессов в трейд-маркетинге. Сравнительный анализ методов ML показал преимущества алгоритма XGBoost для решения задач прогнозирования продаж благодаря: высокой точности предсказаний; хорошей интерпретируемости результатов; устойчивости к шумам в данных; оптимальной скорости работы.

Архитектура технологического решения на основе PostgreSQL, Power BI и Python обеспечивает: надежное хранение больших объемов данных; эффективную обработку и анализ информации; наглядную визуализацию результатов; автоматизацию бизнес-процессов через Airflow.

Проведенный анализ сравнения применения машинного обучения (ML) в трейд-маркетинге между российскими компаниями и зарубежными гигантами (такими как *Walmart* или *Procter & Gamble*) показывает значи-

тельные различия в зрелости, масштабе, интеграции данных и стратегическом подходе.

Зарубежные лидеры (Walmart, P&G) используют ML в трейд-маркетинге как стратегический, масштабируемый и интегрированный инструмент, тогда как в России подход пока фрагментированный, пилотный и реактивный. Однако разрыв сокращается: российские игроки активно наверстывают упущенное, особенно в условиях необходимости повышения эффективности при ограниченных ресурсах.

Таблица 1.

Сравнительный анализ зарубежных и российских компаний

Параметр	Зарубежные компании (Walmart / P&G)	Российские компании
Глубина интеграции	Полная: от поставщика до кассы	Частичная: в основном внутри своей экосистемы
Доступ к данным	Прямой обмен с ритейлерами	Ограниченный; редко есть данные о конкурентах
Масштаб	Глобальный, 1000+ SKU	Локальный, часто пилоты на 10–50 SKU
Цель ML	Максимизация ROI trade spend	Оптимизация внутренних процессов
Технологии	Собственные ML-платформы + AI	Часто внешние решения или open-source (CatBoost, LightGBM)

Зарубежные компании используют ML стратегически, чтобы управлять миллиардными бюджетами trade marketing с максимальной отдачей. Российские игроки пока делают операционные улучшения, но быстро наращивают компетенции. Ключевой барьер – не технологии, а доступ к сквозным данным и культура принятия решений на основе аналитики.

Применение аналитических инструментов позволяет решать ключевые задачи трейд-маркетинга: оптимизацию товарных запасов и логистики; персонализацию маркетинговых активностей; повышение точности прогнозирования спроса; улучшение взаимодействия с торговыми сетями.

Особую значимость предложенный подход приобретает для табачной продукции, где жесткое регулирование рынка и высокая конкуренция требуют особой точности в планировании и оперативности в принятии решений.

В ходе исследования были использованы данные из нескольких ключевых источников. Основу составили транзакционные данные, выгруженные из корпоративной системы 1С, которые содержали детальную информацию

о продажах табачной продукции за отчетный период. Эти данные включали номенклатуру товаров, количественные показатели продаж в штуках, валовую прибыль по месяцам, а также средний чек по торговым точкам. Дополнительно были получены данные о клиентах, содержащие сведения о географической принадлежности (город, регион), виде торговой точки, показателях лояльности и активности покупателей.

Для хранения и обработки аналитических данных была развернута самая популярная опенсорсная система управления базами данных PostgreSQL [1; 2], версия 16.11.

Особенностью работы с данными стала необходимость решения проблемы кодировки – исходные данные из системы 1С использовали кодировку Windows-1251 (CP1251), что потребовало дополнительного этапа конвертации перед загрузкой в PostgreSQL. Процесс загрузки данных включал несколько последовательных этапов. На первом этапе была подготовлена среда для работы с данными – установлена соответствующая кодовая страница (1251) для корректного отображения кириллических символов при помощи команды `chcp 1251`. Затем выполнено подключение к серверу PostgreSQL через утилиту `psql` с аутентификацией под пользователем `Postgres`.

Далее была создана структура базы данных, включающая таблицы «Второй_год», «Третий год», «Четвёртый год» с полями для хранения всей необходимой информации: от идентификационных данных клиентов и их географической принадлежности до детализированных показателей продаж по месяцам. Особое внимание было уделено выбору типов данных – для финансовых показателей использовался тип `NUMERIC (10,2)`, гарантирующий точность расчетов, а для текстовых данных – `VARCHAR` с достаточным запасом по длине.

Загрузка данных осуществлялась с использованием утилиты `psql` и команды `COPY`, которая позволяла импортировать данные из CSV-файлов с указанием исходной кодировки (`WIN1251`).

Отдельной задачей стало преобразование кодировок текстовых данных из `WIN1251` в `UTF-8`, которое выполнялось средствами PostgreSQL с использованием функций `convert_from` и `convert_to`. Этот этап был критически важен для обеспечения корректного отображения всех текстовых данных в аналитических отчетах и визуализациях.

В рамках исследования была проведена комплексная сегментация клиентской базы с последующим прогнозированием продаж для каждого выделенного сегмента. Основой для анализа послужили исторические данные о продажах.

Для построения прогнозной модели был выбран алгоритм XGBoost. Выбор XGBoost (eXtreme Gradient Boosting) в задачах трейд-маркетинга (например, прогнозирование спроса, оценка эффективности промоакций, персонализация предложений) обоснован сочетанием точности, устойчивости, гибкости и зрелости экосистемы [3; 4].

Особенностью реализации стало использование взвешенного подхода к обучению модели, учитывающего неравномерность распределения данных по различным товарным категориям и регионам.

Процесс настройки аналитического окружения потребовал тщательного подхода к управлению зависимостями. Было создано изолированное окружение Python 3.8 с использованием Anaconda, что обеспечило воспроизводимость результатов и избежание конфликтов версий. Установленные пакеты включали не только базовые библиотеки для анализа данных (pandas, numpy), но и специализированные инструменты для работы с временными рядами (pmdarima, sktime), ансамблевыми методами (xgboost, lightgbm) и инструментами AutoML (AutoGluon, AutoSklearn, TPOT, PyCaret) [5].

Интеграция аналитического решения с Power BI Desktop была реализована через прямое подключение Python-скриптов к дашбордам. Это позволило создать динамические отчеты, где прогнозные значения автоматически пересчитываются при обновлении исходных данных [6; 7].

Структурирование данных включало создание нормализованной схемы базы данных с четким разделением на справочники (товары, клиенты, регионы) и фактические данные (транзакции, маркетинговые активности) (Рис. 1).

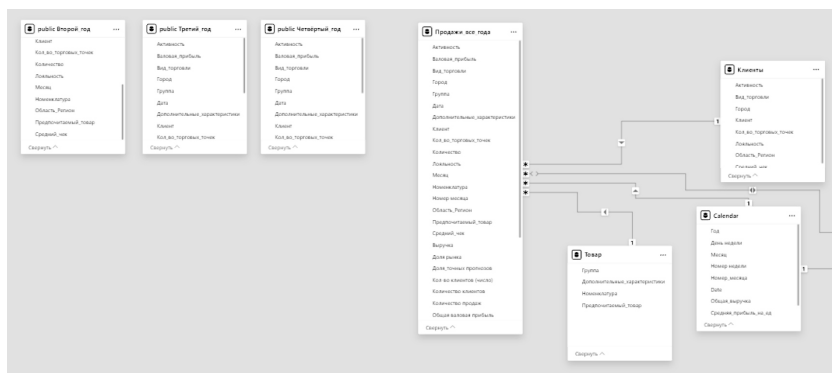


Рис. 1. Модель базы данных

Обработка данных, также включала в себя удаление не нужных столбцов, определение типов данных, замену значений, фильтрацию по необходимым для интерпретации и визуализации данных критериям.

Сегментация клиентов требует тщательного проектирования структуры данных и внедрение специализированных метрик. Поэтому в PowerBI были созданы меры облегчающие расчёты и анализ данных, в качестве примера предлагается рассмотреть некоторые из них: создание временного календаря как отдельной сущности. Данная мера позволила унифицировать работу с датами и в последствии избежать пропущенных значений или ошибок в исходных данных. Разработка ключевых показателей для оценки клиентской активности и товарной рентабельности.

Таким образом, данные удалось подготовить для анализа и визуализации, что в дальнейшем повлияло на сегментацию клиентской базы. Визуализация исходных данных представлена в рисунок 2, 3.

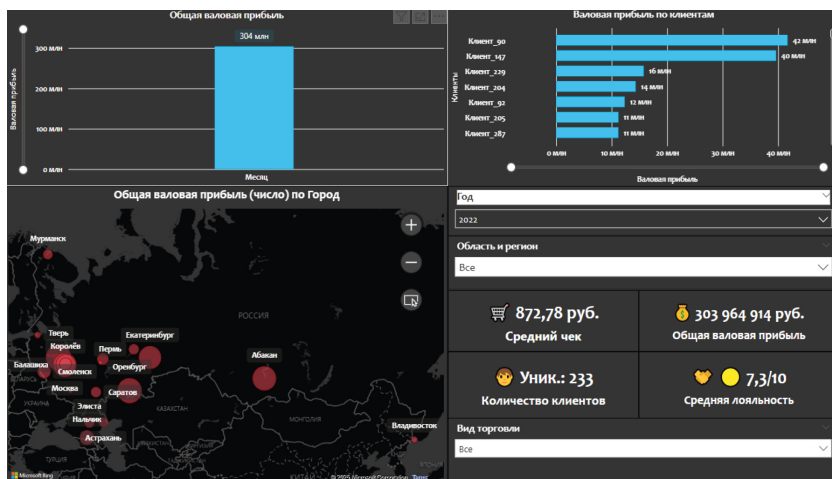


Рис. 2. Общая аналитика

Для сегментации клиентов необходимо было подойти к вопросу аналитики комплексно, именно поэтому было принято решение составить несколько дашбордов, которые будут показывать:

1. Общую аналитику, где представлена общая валовая прибыль в разрезе города, клиента, даты, вида торговли.
2. Аналитику продаж, которая отражает тренд продаж, средний чек продажи в разрезе дня недели, недели месяца и т.п.
3. Клиентскую аналитику, которая показывает активность клиентов, количество продаж по городам и количеству торговых точек.

4. Товарную аналитику, которая отражает основные экономические показатели компании по продажам.



Рис. 3. Клиентская аналитика

В рамках работы стояла задача не только автоматизировать процесс обработки и анализа данных, но и разработать ML-модель, которая будет прогнозировать продажи в разрезе клиентов, тем самым, благоприятно влияя на персонализацию маркетинговых предложения для клиентов и партнёров.

Реализация ML-модели осуществлялась на языке Python с использованием библиотек `scikit-learn` и `pandas`, благодаря чему удалось создать масштабируемое решение, которое возможно интегрировать с Power BI.

Процесс разработки модели включал в себя следующие этапы:

1. Обработку пропущенных значений, устранение выбросов методом `winsorization` (с границами на уровне 1 и 99 перцентилей) и логарифмическое преобразование целевой переменной для нормализации распределения. Выделены временные признаки - год, месяц, день недели и квартал каждой продажи, что позволило учесть сезонные колебания спроса [8].
2. Чтобы сделать модель наиболее точной, были созданы лаговые признаки, к примеру значение продаж за предыдущие периоды, а также применялась скользящая статистика, то есть среднее и стандартной отклонение за 3 месяца. Данные признаки помогли учесть динамику спроса у каждого клиента.

3. Разделение данных на обучающую и тестовую выборки проводилось с сохранением всех клиентов в каждой выборке (70%/30%), что обеспечило репрезентативность оценки качества модели.

Архитектура модели основана на HistGradientBoostingRegressor. Модель настроена с учетом специфики задачи:

Максимальная глубина деревьев: 4

Минимальное количество образцов в листе: 30

Скорость обучения: 0.05

L2-регуляризация: 1.5

Ранняя остановка при отсутствии улучшений.

Для оценки качества модели использованы четыре ключевые метрики (Рисунок 4).

Метрика	Train	Test
MAE	12.41	13.55
RMSE	38.93	41.47
R2	0.966	0.955
MAPE (%)	7.1	9.54

Рис. 4. Результаты обучения ML-модели

Таким образом, полученные результаты демонстрируют высокую точность модели - средняя абсолютная ошибка составляет менее 14 единиц продукции, а коэффициент детерминации R^2 близок к 1, что указывает на excellent объясняющую способность модели. Небольшое увеличение ошибок на тестовой выборке (около 9%) свидетельствует об отсутствии переобучения.

Метод train/test split предполагает разделение исходных данных на обучающую (70-80%) и тестовую (20-30%) выборки для оценки качества модели. В данном исследовании этот метод был выбран, так как он позволяет объективно оценить способность модели к обобщению на новых данных, не участвовавших в обучении [9]. Этот подход позволил сохранить баланс между затратами на ресурсы и надежностью оценки, что важно для оперативного внедрения модели в бизнес-процессы.

ML-модель прогнозирования продаж стала основой для создания персонализированных предложений для клиентов. Для ведущих клиентов с высо-

ким показателем лояльности сделан акцент на премиальном ассортименте товара и особых условиях поставок. Среднему сегменту клиентов удалось дать рекомендации по оптимизации закупочных объемов и повышению уровня продаж. Для новых клиентов разработаны специальные вводные условия.

Ключевым элементом такого результата стала интеграция ML- модели в Power BI при помощи инструмента «Скрипт Python». Для реализации данного метода необходимо было правильно настроить окружение. Во-первых, был создан Python-интерпретатор с необходимыми зависимостями, путь к которому указан в настройках Power BI (C:\Users\Ghost\Anaconda3\envs\rusacret_pbi). Во-вторых, необходимо было предварительно обработать данные в Power Query с использованием Python-скрипта, что позволило сохранить всю бизнес-логику прогнозирования в едином месте. В-третьих, необходимо было настроить расписание обновления, кеширование промежуточных результатов, обработку ошибок и уведомления о сбоях.

После внедрения и реализации ML-модели для облегчения интерпретации данных, необходимо было визуализировать полученные результаты в рамках поставленных отделом трейд-маркетинга целей. Таким образом, при помощи инструментов визуализации Power BI были созданы следующие графики:

1. Прогноз продаж по клиентам
2. Прогноз продаж по городам
3. Прогноз продаж по номенклатуре
4. Топ-10 клиентов по прогнозируемому товару (рис. 5).

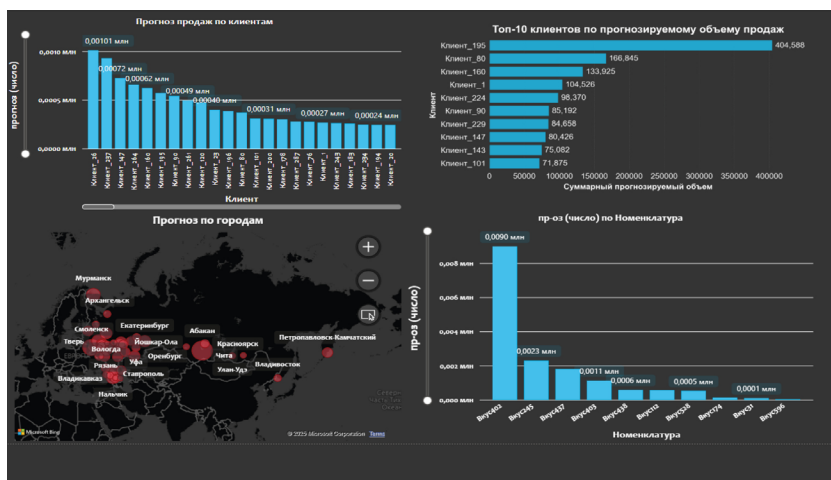


Рис. 5. Прогнозы продаж

Для мониторинга эффективности модели был разработан дашборд в Power BI, где наглядно отображены ключевые метрики оценки модели.

На дашборде отображены следующие графики:

1. Распределение прогнозируемых значений продаж – гистограмма с кривой плотности показывает диапазон спрогнозированных продаж. Из график можно увидеть, что основная масса прогноза (68%) сосредоточена в диапазоне от 250 до 750 единиц. Распределение имеет правостороннюю асимметрию, характерную для товаров с периодическим всплеском спроса.
2. Сравнение фактических и прогнозируемых значений – точечная диаграмма с линией идеального прогноза. Из графика видны точность модели ($R^2 = 0.93$), Среднюю абсолютную ошибку 24.9 единицы, концентрацию точек вдоль линии идеального прогноза, подтверждающую адекватность прогноза, незначительное занижение прогноза для заказов свыше 1000 шт.
3. Распределение отклонений прогноза – нормализованная гистограмма, которая показывает среднее отклонение (-0,21), стандартное отклонение (56.56), симметричность распределения вокруг 0, Прогноз имеет отклонение в основном в пределах +/- 100 ед.
4. Анализ ошибок модели – Гистограмма, которая отражает MAE -6.17 при стандартном отклонении 56.56, преобладание незначительных ошибок (до 50 ед.), выбросы с отклонениями свыше 500 ед., которые редко встречаются на гистограмме.

Таким образом, результаты подтвердили адекватность и стабильность модели на разных временных отрезках. Отсутствие систематических смещений прогноза, правильность выбранного метода машинного обучения [10; 11].

Технически данный дашборд был реализован через инструмент визуализации Python, динамическое обновление при изменении исходных данных, автоматических пересчет метрик, интерактивные элементы фильтрации.

Таким образом, практическая реализация системы аналитики для трейд-маркетинга позволила достичь следующих ключевых результатов:

Разработана система обработки и анализа данных:

Осуществлен перенос данных из Excel в PostgreSQL с решением проблем кодировки.

Создана нормализованная структура базы данных с историческими данными за 4 года.

Реализованы механизмы автоматической загрузки и конвертации данных. Проведена качественная подготовка данных для анализа:

1. Выполнена очистка и трансформация данных
2. Разработаны специализированные метрики в Power BI
3. Созданы интерактивные дашборды для различных аспектов аналитики
4. Построена и протестирована ML-модель прогнозирования: выбран алгоритм XGBoost как оптимальный для задач трейд-маркетинга
5. Достигнута высокая точность прогнозов (MAE 24.9 ед., $R^2=0.93$)
6. Обеспечена интерпретируемость результатов для бизнес-пользователей
7. Реализована система визуализации и интеграции:
8. Настроена автоматическая публикация отчетов через Power BI Report Server

Обеспечен контролируемый доступ к аналитическим данным. Особое значение имеет успешная интеграция всех компонентов системы. PostgreSQL обеспечивает надежное хранение данных Python используется для сложной аналитики и ML. Power BI предоставляет удобные инструменты визуализации

Полученные результаты подтверждают правильность выбранных технологических решений и создают основу для дальнейшего развития системы, в частности: внедрения динамического ценообразования; расширения функционала прогнозных моделей; разработки мобильных приложений для торговых представителей; внедрение системы прогнозирования на основе ML-модели значительно увеличит точность прогнозирования, благодаря чему экономические показатели кампании значительно улучшатся.

Прогноз позволит:

1. Оптимизировать товарные запасы за счёт, сокращения затрат на хранение избыточного товара, уменьшения потери от недопродаж на 5-10% за счёт своевременного пополнения складов.
2. Повысить эффективность промо-акций, так как модель предсказывает спрос на товары, что позволяет снизить количество излишков товара на акционные товары, уменьшить дефицит товара во время промо-периода, оптимизировать распределение товара по городам
3. Снизить затраты на логистику, так как прогнозирование пиков роста спроса позволит уменьшить расходы на срочные перевозки и сверхнормативные заказы.
4. Увеличить маржинальность при помощи использования прогноза для ценорегулирования в периоды низкого/высокого спроса.

Таким образом, модель значительно улучшит ситуацию кампании, учитывая только внутренний трейд-маркетинг кампании и позволит выйти ей на новый уровень. Также стоит учитывать внешний маркетинг, необходимо понимать, что есть определённые риски:

1. Неучтённые внешние факторы (Например, изменение поведения конкурентов, изменение экономической, законодательной ситуации в стране).
2. Ошибки в данных.

При внедрении модели стоит учитывать технические требования, к примеру необходимость интеграции с ERP и CRM системами, определённые требования к вычислительным ресурсам для обработки больших данных, обучения сотрудников работе с системой.

Внедрение системы прогнозирования спроса позволит компании достичь комплексного улучшения экономических показателей, примерно на 20 %. При этом для реализации полного потенциала системы потребуется: интеграция с существующими ИТ-системами, адаптация бизнес-процессов, постоянный мониторинг и обновление модели.

Список литературы

1. Stack Overflow. (2025). *Самые популярные технологии: базы данных* [Онлайн-опрос]. Получено из <https://survey.stackoverflow.co/2025/technology#most-popular-technologies-database> (дата обращения: 01.12.2025).
2. Paiva, C. A. et al. (2025). Analyzing the adoption of database management systems throughout the history of open source projects. *Empirical Software Engineering*, 30(3), 71. <https://doi.org/10.1007/s10664-025-10627-z>. EDN: <https://elibrary.ru/CBUKZW>
3. Chen, T. (2016). *XGBoost: A scalable tree boosting system*. Cornell University.
4. Mitchell, R. (2017). *Gradient boosting, decision trees and XGBoost with CUDA*. Получено из <https://devblogs.nvidia.com/parallelforall/gradient-boosting-decision-trees-xgboost-cuda/> (дата обращения: 01.12.2025).
5. Aragão, M. V. C. et al. (2025). A practical evaluation of AutoML tools for binary, multiclass, and multilabel classification. *Scientific Reports*, 15(1), 17682. <https://doi.org/10.1038/s41598-025-02149-x>. EDN: <https://elibrary.ru/SZYPEK>
6. Darmawan, R., & Swalaganata, G. (2025). Analisa komparatif Power BI dan Tableau dalam implementasi business intelligence pada Brazilian ecommerce public dataset by Olist. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(5), 8936–8944. <https://doi.org/10.36040/jati.v9i5.15178>. EDN: <https://elibrary.ru/FAZGHL>
7. Panda, S. P., & Padhy, A. (2025). *Business intelligence with Power BI and Tableau: Cloudbased data warehousing, predictive analytics, and artificial intelligencedriven decision support*. Deep Science Publishing.

8. Sangeetha, R., Elantamilan, D., & Indrapandi, A. (2025). Analyzing data with different charts and visualizations in Power BI. *Metallurgical and Materials Engineering*, 31(1), 780–785.
9. Ernesti, J. et al. (2025). *Python 3: The comprehensive guide*. Packt Publishing Ltd.
10. RogelSalazar, J. (2025). *Data science and analytics with Python*. Chapman and Hall/CRC.
11. Navarro, C. L. A. et al. (2021). Risk of bias in studies on prediction models developed using supervised machine learning techniques: Systematic review. *BMJ*, 375.

References

1. Stack Overflow. (2025). *The most popular technologies: Databases* [Online survey]. Retrieved from: <https://survey.stackoverflow.co/2025/technology#-most-popular-technologies-database> (Accessed: December 1, 2025)
2. Paiva, C. A. et al. (2025). Analyzing the adoption of database management systems throughout the history of open source projects. *Empirical Software Engineering*, 30(3), 71. <https://doi.org/10.1007/s10664-025-10627-z>. EDN: <https://elibrary.ru/CBUKZW>
3. Chen, T. (2016). *XGBoost: A scalable tree boosting system*. Cornell University.
4. Mitchell, R. (2017). *Gradient boosting, decision trees and XGBoost with CUDA*. Retrieved from: <https://devblogs.nvidia.com/parallelforsall/gradient-boosting-decision-trees-xgboost-cuda/> (Accessed: December 1, 2025)
5. Aragão, M. V. C. et al. (2025). A practical evaluation of AutoML tools for binary, multiclass, and multilabel classification. *Scientific Reports*, 15(1), 17682. <https://doi.org/10.1038/s41598-025-02149-x>. EDN: <https://elibrary.ru/SZYPEK>
6. Darmawan, R., & Swalaganata, G. (2025). Analisa komparatif Power BI dan Tableau dalam implementasi business intelligence pada Brazilian ecommerce public dataset by Olist. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 9(5), 8936–8944. <https://doi.org/10.36040/jati.v9i5.15178>. EDN: <https://elibrary.ru/FAZGHL>
7. Panda, S. P., & Padhy, A. (2025). *Business intelligence with Power BI and Tableau: Cloud based data warehousing, predictive analytics, and artificial intelligence driven decision support*. Deep Science Publishing.
8. Sangeetha, R., Elantamilan, D., & Indrapandi, A. (2025). Analyzing data with different charts and visualizations in Power BI. *Metallurgical and Materials Engineering*, 31(1), 780–785.
9. Ernesti, J. et al. (2025). *Python 3: The comprehensive guide*. Packt Publishing Ltd.
10. Rogel Salazar, J. (2025). *Data science and analytics with Python*. Chapman and Hall/CRC.
11. Navarro, C. L. A. et al. (2021). Risk of bias in studies on prediction models developed using supervised machine learning techniques: Systematic review. *BMJ*, 375.

ДАННЫЕ ОБ АВТОРАХ

Сахнюк Татьяна Ивановна, кандидат экономических наук, доцент
Московский городской педагогический университет
2-й Сельскохозяйственный проезд, 4, г. Москва, 129226, Российская
Федерация
tatiana-sahnyuk@yandex.ru

Коршикова Марина Викторовна, кандидат экономических наук, доцент
Ставропольский государственный аграрный университет
пер. Зоотехнический, 12, г. Ставрополь, 355035, Российская Феде-
рация
kumavi@mail.ru

Сахнюк Павел Анатольевич, кандидат технических наук, доцент
Финансовый университет при Правительстве Российской Фе-
дерации
пр-кт Ленинградский, 49/2, г. Москва, 125167, Российская Феде-
рация
sahnyuk@yandex.ru

DATA ABOUT THE AUTHORS

Tatyana I. Sakhnyuk, PhD in Economics, Associate Professor
Moscow City Pedagogical University
4, 2nd Selskokhozyaistvenny Proezd, Moscow, 129226, Russian Federation
tatiana-sahnyuk@yandex.ru

Marina V. Korshikova, PhD in Economics, Associate Professor
Stavropol State Agrarian University
12, Zootechnichesky Lane, Stavropol, 355035, Russian Federation
kumavi@mail.ru

Pavel A. Sakhnyuk, PhD in Engineering, Associate Professor
Financial University under the Government of the Russian Federation
49/2, Leningradsky Prospekt, Moscow, 125167, Russian Federation
sahnyuk@yandex.ru

Поступила 02.12.2025

После рецензирования 18.12.2025

Принята 21.12.2025

Received 02.12.2025

Revised 18.12.2025

Accepted 21.12.2025