

ПРИМЕНЕНИЕ СОВРЕМЕННЫХ СРЕДСТВ АДАПТИВНОГО ПРОГНОЗИРОВАНИЯ И ПРЕДИКТИВНОЙ АНАЛИТИКИ ДЛЯ АНАЛИЗА КЛИЕНТСКОЙ УДОВЛЕТВОРЕННОСТИ

Е.А. Павлова, С.П. Бобков, О.Л. Ксенофонтова, О.П. Смирнова

Екатерина Алексеевна Павлова* (ORCID 0000-0002-9266-9603), Сергей Петрович Бобков (ORCID 0000-0001-7315-1625), Ольга Леонидовна Ксенофонтова (ORCID 0000-0002-4122-6220), Ольга Павловна Смирнова (ORCID 0009-0003-2941-5365)

Ивановский государственный химико-технологический университет», пр. Шереметевский, 7, Иваново, 153000, Россия

E-mail: pavlova_ea@isuct.ru*, bsp@isuct.ru, olga_izvolova@mail.ru, smirnova_op@isuct.ru

Статья посвящена вопросам предиктивной аналитики и адаптивного прогнозирования, представляющим собой передовую технологию, направленную на разработку и применение моделей для предсказательных целей посредством анализа больших данных. Рассматриваются современные инструменты и методики, применяемые в рамках данных направлений, такие как нейронные сети, градиентный бустинг и случайный лес, для решения задач машинного обучения. Исследуется проблема точности прогнозирования, возникающая вследствие динамичности и изменчивости окружающей среды, приводится обоснование важности адаптивных методов в контексте требований современной цифровой экономики. Обосновывается необходимость постоянного обновления и адаптации моделей, подчёркивая их значимость для компаний различного профиля.

Подчёркнута важность использования качественного набора данных и правильного выбора метода для каждого отдельного случая. Представленные выводы доказывают эффективность применения методов машинного обучения для повышения удовлетворенности клиентов с целью укрепления конкурентных позиций на рынке.

Ключевые слова: предиктивная аналитика, адаптивное прогнозирование, машинное обучение, индекс потребительской лояльности (NPS), метод случайного леса, логистическая регрессия, нейронные сети, градиентный бустинг, точность (Accuracy), полнота (Recall), F1-Score, анализ клиентской удовлетворенности.

USING MODERN ADAPTIVE FORECASTING AND PREDICTIVE ANALYTICS TOOLS TO ANALYZE CUSTOMER SATISFACTION

E.A. Pavlova, S.P. Bobkov, O.L. Ksenofontova, O.P. Smirnova

Ekaterina A. Pavlova* (ORCID 0000-0002-9266-9603), Sergey P. Bobkov (ORCID 0000-0001-7315-1625), Olga L. Ksenofontova (ORCID 0000-0002-4122-6220), Olga P. Smirnova (ORCID 0009-0003-2941-5365)

Ivanovo State University of Chemistry and Technology, 7 Sheremetevsky Avenue, Ivanovo, 153000, Russia

E-mail: pavlova_ea@isuct.ru*, bsp@isuct.ru, olga_izvolova@mail.ru, smirnova_op@isuct.ru

The article focuses on predictive analytics and adaptive forecasting, which are advanced technologies aimed at developing and applying models for predictive purposes through big data analysis. Modern tools and methodologies used in these areas and applied to solve machine learning tasks are discussed, including neural networks, gradient boosting, and random forests. The problem of forecasting accuracy arising from the dynamism and variability of the environment is explored, and the importance of adaptive methods within the context of modern digital economy requirements is substantiated. The necessity of continuous updating and adaptation of models is justified, highlighting their significance for companies of various profiles.

The importance of using high-quality datasets and proper method selection for each specific case is emphasized. The presented conclusions demonstrate the effectiveness of applying machine learning techniques to enhance customer satisfaction in order to strengthen competitive positions in the market.

Keywords: predictive analytics, adaptive forecasting, machine learning, net promoter score (NPS), random forest method, logistic regression, neural networks, gradient boosting, Accuracy, Recall, F1-score, customer satisfaction analysis.

Для цитирования:

Павлова Е.А., Бобков С.П., Ксенофонтова О.Л., Смирнова О.П. Применение современных средств адаптивного прогнозирования и предиктивной аналитики для анализа клиентской удовлетворенности. *Известия высших учебных заведений. Серия «Экономика, финансы и управление производством» [Ивэкофин]*. 2026. № 01(67). С. 178-185. DOI: 10.6060/ivecofin.2026671.772

For citation:

Pavlova E.A., Bobkov S.P., Ksenofontova O.L., Smirnova O.P. Using modern adaptive forecasting and predictive analytics tools to analyze customer satisfaction. *Ivecofin*. 2026. N 01(67). P. 178-185. DOI: 10.6060/ivecofin.2026671.772 (in Russian)

ВВЕДЕНИЕ

Предикативная аналитика и средства адаптивного прогнозирования на сегодняшний день считаются современными технологическими решениями задач имитационного прогнозирования на основе анализа данных. Все большее количество ученых [1-5] и практиков используют такие подходы, расширяя со временем область их применения.

Принимая во внимание факт того, что с каждым днем увеличиваются объемы накопленных данных, растет количество исследований полученных данных, особую актуальность приобретает применение современных средств адаптивного прогнозирования и предиктивной аналитики, основной задачей которых считается создание надежных моделей для оперативного реагирования на изменение внешней среды и учет характеристик, особенностей и свойств исследуемых объектов.

Сегодня проблема точности прогнозирования становится ключевой в вопросах принятия решений, зачастую ошибки являются настолько критичными, что приводят к необратимым последствиям в различных отраслях производства, сферы услуг, инфраструктурных отраслях и государственном управлении. Можно с уверенностью сказать, что в большинстве своем традиционные методы прогнозирования оказываются неэффективными ввиду своей ограниченной функциональности и низкой приспособленности к изменяющимся условиям. Вследствие этого в вопросах прогнозирования в настоящий момент времени активно применяют новые подходы, способные обеспечить необходимый уровень адаптивности и интенсифицировать процесс реагирования на происходящие изменения.

В отличие от традиционных методов прогнозирования, современные средства адаптивного прогнозирования и предиктивной аналитики опираются на последние достижения математики, статистики и информатики. Современные инструмен-

тальные средства включают разнообразные технологии от классических регрессионных моделей до современных методов машинного обучения. Основным отличием современных подходов прогнозирования можно назвать способность учитывать случайные отклонения и нелинейные зависимости, что является важнейшим дополнением современных методов прогнозирования, поскольку именно нелинейные зависимости и флуктуации характерны для реальных процессов и отражают природу неопределенности окружающего мира.

Особенность адаптивного прогнозирования заключается в способности непрерывно корректировать параметры модели в режиме реального времени, что повышает ее чувствительность к внешним факторам и снижает погрешность прогноза. Благодаря этому возможно значительное улучшение качества принимаемых решений и минимизация риска ошибочных действий.

В представленной статье описываются разные подходы к решению задач машинного обучения, каждый из которых имеет свою специфику и области применения. Особое внимание уделяется алгоритму действий при применении методов прогнозирования. Описаны этапы разработки и тестирования предлагаемых моделей, кроме того, приведены примеры практического применения в части анализа клиентской удовлетворенности. Традиционные методы оценки удовлетворенности зачастую не учитывают изменчивость предпочтений и специфику больших объемов данных. Применение адаптивных методов анализа и алгоритмов машинного обучения позволяет повысить точность прогнозирования уровня удовлетворённости клиентов и оперативно адаптировать бизнес-процессы под изменяющиеся условия. Адаптивное прогнозирование обеспечивает динамическую настройку модели под изменяющиеся условия, что критически важно в условиях цифровой среды. Использо-

ние современных средств адаптивного прогнозирования и предиктивной аналитики позволяет выявлять скрытые зависимости в пользовательском поведении и оперативно адаптировать стратегию взаимодействия. Предложенное и подобные решения могут быть интегрированы в системы управления клиентским опытом для повышения качества обслуживания и оперативного реагирования на риски снижения удовлетворённости.

МАТЕРИАЛЫ И МЕТОДЫ

Представленная статья служит доказательством применения методов предиктивной аналитики и адаптивного прогнозирования, решающего вопросы анализа клиентской удовлетворённости. Материалы исследования базируются на применении специализированных алгоритмов и методик с целью последующего прогнозирования поведения изучаемых объектов. Реализация метода прогнозирования была осуществлена с применением языка программирования Python и библиотек, таких как Pandas, NumPy, Scikit-learn и TensorFlow, которые обеспечили обработку данных и машинное обучение. Для исследования использован набор данных, содержащий результаты опроса пассажиров авиакомпаний об уровне удовлетворённости (сбор первичных данных о степени удовлетворённости клиентов услугами компаний), отзывы клиентов, полученные через социальные сети, а также сбор метрик взаимодействия (отслеживание поведения клиентов на веб сайтах и мобильных приложениях). Методами машинного обучения можно назвать следующие: линейная регрессия (для выявления корреляций), деревья решений и случайные леса (для классификации клиентов по уровню удовлетворённости), нейронные сети (для предсказания будущего уровня удовлетворённости на основе ретроспективных данных), градиентный бустинг (для повышения точности прогнозов и классификации).

Стоит отметить, что исследование проводилось в три этапа: в рамках сбора и подготовки данных осуществлялся сбор первичной информации о клиентах, очистка данных от пропущенных значений и неточностей, нормализация данных для дальнейшего анализа, далее осуществлялся этап моделирования и прогнозирования данных с применением методов машинного обучения для выявления факторов, влияющих на уровень клиентской удовлетворённости и непосредственно интерпретация результатов путем проверки точности построенных моделей и оценки их эффективности.

В процессе литературного обзора и детального изучения методов адаптивного прогнозирования, можно отметить, что предложенный метод прогнозирования позволяет создать такой

подход, при котором система адаптируется к изменениям в динамически меняющихся условиях среды. Предложенная технология находит применение в различных отраслях, обеспечивая высокую точность прогнозов и эффективность принятия решений [1, 6].

РЕЗУЛЬТАТЫ

В условиях цифровизации и растущей рыночной конкуренции удовлетворённость клиентов становится первостепенным фактором успешной работы компаний, особенно на цифровых платформах. Уровень удовлетворённости клиентов, который можно интерпретировать как высокий и стабильно высокий, укрепляет лояльность, увеличивает повторные взаимодействия и способствует повышению эффективности бизнеса. Более того, в настоящее время, в эпоху высокой конкуренции, важно не только реагировать на запросы клиентов, но и предугадывать изменения их поведения и прогнозировать ожидания.

Традиционные методы оценки клиентского опыта: опросы, интервью, статистический анализ, нередко оказываются недостаточно точными и оперативными, особенно в быстро меняющейся цифровой среде. Это обусловлено рядом ограничений, среди которых можно выделить статичность и неспособность отслеживать изменения клиентских предпочтений, ограниченные выборки и значительные временные затраты на обработку и интерпретацию значений. Эти ограничения делают традиционные подходы менее пригодными для современного цифрового окружения, характеризующегося небольшими объемами данных и быстрыми изменениями рыночных условий. В связи с этим возрастает значимость интеллектуальных методов анализа, включая машинное обучение [7, 8].

Современные технологии машинного обучения позволяют точнее и гибче прогнозировать удовлетворённость клиентов. Особое внимание заслуживают адаптивные алгоритмы, которые не только учитывают изменения условий, но и обновляют прогнозы по мере поступления новых данных. В отличие от статичных моделей, такие методы чувствительны к текущим трендам и выявляют скрытые зависимости в поведении пользователей.

Эти ограничения делают традиционные подходы менее пригодными для современного цифрового окружения, характеризующегося небольшими объемами данных и быстрыми изменениями рыночных условий.

С целью преодоления вышеуказанных недостатков традиционных методов прогнозирования, современные исследователи активно внедряют адаптивные методы анализа и применяют передовые технологии машинного обучения

[9-11]. Среди основных преимуществ такого подхода можно выделить, во-первых, повышенную точность прогнозирования, обусловленную способностью выявлять скрытые взаимосвязи и закономерности в больших объемах данных. Во-вторых, автоматизацию процесса сбора и обработки информации, что значительно снижает трудозатраты и повышает эффективность системы. И, наконец, в-третьих, возможность оперативной адаптации бизнес-процессов, благодаря непрерывному мониторингу и анализу данных анализируемой системы, возможности вносить корректировки данных. При этом важно отметить, что, применяя средства адаптивного прогнозирования и превентивной аналитики важно обладать значительным набором данных, большой выборкой для исследования, что зачастую становится проблемой частью проведения любого вида исследования. Это связано с тем, что недостаточная выборка может привести к искажению результатов исследования, снижению точности прогнозов и неверному толкованию тенденций развития исследуемых объектов. Важно отметить, что на сегодняшний день основная сложность заключается не столько в применяемых методах анализа, а сколько в поиске самих массивов больших объемов данных. Приходится сталкиваться с проблемами доступности, конфиденциальности, качества данных, а зачастую и со стоимостью получения данных для исследования.

Целью работы было выявление наиболее эффективных подходов к решению задачи и оценка их точности на реальных примерах из разных сфер бизнеса. Использовались стандартные метрики оценки производительности моделей, включая индекс потребительской лояльности (Net Promoter Score, NPS), показатель точности (Accuracy), полноту (Recall) и комбинированную метрику F1-Score. Работа демонстрирует, что применение этих методов обеспечивает значительное улучшение понимания потребностей клиентов и возможностей для повышения качества обслуживания.

Среди распространенных методов, используемых для решения задач классификации, выделяются случайный лес, логистическую регрессию, нейронные сети и градиентный бустинг [9, 10]. Каждый из этих методов имеет свои особенности и сферы применения, считаем, что их сравнение позволит выбрать оптимальный подход для конкретной задачи. В работе применены все вышеуказанные методы, более того, авторы провели исследования и сравнение вышеуказанных методов в контексте анализа клиентской удовлетворенности.

Метод случайного леса (Random Forest) представляет собой ансамбль классификаторов, основанных на деревьях решений. Основное преимущество метода заключается в его способности

справляться с большим количеством признаков и устойчивости к переобучению. Этот метод также легко интерпретируется и способен выявить важные признаки, влияющие на итоговый результат.

Логистическая регрессия применяется для бинарной классификации, когда задача сводится к определению принадлежности объекта к одному из двух классов («довольный клиент» или «недовольный клиент»). Модель основана на линейной комбинации признаков и вероятности принадлежности к классу, рассчитываемой функцией сигмоиды. Хотя эта модель проще случайного леса, она широко используется в практических приложениях из-за своей простоты и прозрачности.

Нейронные сети представляют собой мощные инструменты для моделирования сложных нелинейных зависимостей. Глубокое обучение позволяет создавать многослойные архитектуры, способные извлекать высокоуровневые признаки из исходных данных. Однако такие модели требуют больше вычислительных ресурсов и больших объемов данных для эффективной тренировки.

Градиентный бустинг (Gradient Boosting) представляет собой алгоритм построения ансамбля слабых классификаторов путем последовательного добавления деревьев решений. Метод обладает высокой точностью, но требует тщательной настройки гиперпараметров и склонен к переобучению при недостаточном контроле.

Эксперимент проводился на наборах данных из различных областей: маркетинга, розничной торговли, банковского сектора, отрасли гражданской авиации и телекоммуникаций. Для каждой отрасли были собраны данные о поведении клиентов, продуктах и услугах, которыми пользовались клиенты, а также уровнях удовлетворенности, измеренных различными способами, такими как прямые опросы и косвенные показатели (например, частота повторных покупок).

По всем перечисленным моделям проводилась оценка по нескольким критериям. Основными и самыми значимыми из которых можно выделить: индекс потребительской лояльности (NPS); точность (Accuracy); полнота (Recall); эффективность классификации модели машинного обучения (F1-Score).

Выбор именно этих метрик обусловлен их универсальностью и способностью давать полную картину качества классификации.

Проведенный эксперимент показал высокую эффективность всех рассмотренных методов, однако некоторые различия были обнаружены. Можно отметить, что самую высокую точность и полноту показал метод градиентного бустинга. Однако случайный лес оказался лучше по скорости вычислений и простоте интерпретации. Нейронные сети показали лучшие результаты в

случаях, когда количество признаков было значительным, но требовали большего количества вычислительных ресурсов. Относительная простота логистической регрессии сделала её привлекательной для случаев, когда важна ясность процесса принятия решений и ограничены вычислительные мощности.

Далее, при осуществлении авторами результатов исследования, была отмечена высокая значимость у критерия индекса потребительской лояльности (NPS). Это означает, что, включив этот критерий в качестве основного, стало возможным определить удовлетворенность клиентов, используя не только количественные значения, но и применяя качественные показатели для включения в массив данных.

Можно отметить, что применение всех вышеперечисленных методов машинного обучения обосновано и дополняет друг друга. Более того, применение разнообразных методов в оценке и прогнозировании поведения потребителей с применением машинного обучения, выводит на новый уровень возможности бизнеса в целом. Несмотря на разнообразие подходов, которые представлены в результате адаптивного анализа, каждый из предложенных методов демонстрирует свою ценность и значимость для решения определенных целей и особенностей полученных данных для исследования [12-15].

Подводя итог результатам исследования, можно сделать следующие выводы.

1. Все рассматриваемые методы обеспечивают хорошие результаты, но наибольшая точность достигается методом градиентного бустинга.
2. Выбор оптимального подхода зависит от множества факторов, включая доступность вычислительных мощностей, требования к интерпретации и качество собранных данных.
3. Индекс потребительской лояльности (NPS) играет важную роль в улучшении точности прогнозирования удовлетворенности клиентов.
4. Для исследования применялись методы сбора и предварительной обработки данных, разработка и тренировка моделей, проверка их адекватности и интерпретацию полученных результатов.

Исходные данные представляют собой совокупность показателей, характеризующих деятельность сотрудника и выполняемые им задачи. Датасет включал следующие параметры: пол, тип клиента, возраст, цель поездки, класс обслуживания, расстояние полёта, уровень удовлетворенности различными аспектами сервиса (Wi-Fi, время вылета/прилёта, онлайн-бронирование, расположение выхода на посадку, питание, онлайн-регистрация, комфорт сидений, развлечения, обслуживание на борту, пространство для ног, обработка

багажа, регистрация, чистота), а также время задержек при вылете и прилёте. Целевая переменная - общий уровень удовлетворенности пассажира.

Вначале проведен импорт необходимых библиотеки с помощью команды `import`. Для проекта использовались следующие библиотеки:

- `pandas` – работа с табличными данными, загрузка, обработка и анализ в формате `DataFrame`.
- `numpy` – обработка числовых массивов и выполнение математических операций на низком уровне.
- `matplotlib.pyplot` – создание графиков и визуализация данных (диаграммы, графики).
- `seaborn` – высокоуровневая визуализация данных на основе `matplotlib`, создание сложных графиков.
- `sklearn.preprocessing.LabelEncoder` – кодирование категориальных признаков в числовой формат.
- `sklearn.preprocessing.StandardScaler` – нормализация числовых данных для стандартизации распределения.
- `sklearn.model_selection.train_test_split` – разделение данных на обучающую и тестовую выборки.
- `sklearn.ensemble.RandomForestClassifier` – алгоритм классификации на основе ансамбля деревьев решений.
- `sklearn.metrics.accuracy_score` – расчет точности модели на тестовых данных.
- `sklearn.metrics.classification_report` – создание отчета о классификации с метриками `precision`, `recall` и `f1-score`.
- `sklearn.metrics.confusion_matrix` – построение матрицы ошибок для оценки качества классификации по категориям.

На следующем этапе осуществлялась загрузка набора данных для дальнейшей обработки с использованием функции `pd.read_csv` библиотеки `pandas`. Для проверки корректности загрузки выполняется вывод первых строк датасета посредством метода `head`. После загрузки проводился анализ на наличие пропущенных значений с применением метода `isnull`. Далее была осуществлена проверка на сбалансированность данных на примере целевой переменной «satisfaction». В результате видно, что данные достаточно сбалансированы, поэтому повторная выборка не нужна (рис. 1).

Обязательным требованием системы является выявление и устранение выбросов, которые могут существенно исказить результаты дальнейшего анализа. Применяется правило удаления значений, превышающих порог, соответствующий определенному квантилю (например, 90%).



Рисунок 1. Сбалансированность данных на примере целевой переменной

Figure 1. Data balance using the target variable as an example

Проверка наличия выбросов проводилась визуально с помощью диаграмм разброса (boxplot) и статистически путем вычисления квантилей. Далее применялась соответствующая фильтрация данных для устранения экстремально высоких значений.

Следующим важным шагом было заполнение пропущенных значений, используя технику заполнения средней величиной или методом линейной интерполяции.

Перед подачей данных в модель важно привести их к единой шкале. Использовались методы стандартизации (StandardScaler), позволяющие нормализовать числовые признаки к диапазону с нулевым средним и единичным стандартным отклонением.

Категориальные признаки преобразовывались в числовую форму с помощью техники кодирования (LabelEncoding, OneHotEncoding), обеспечивая унификацию форматов и улучшение качества прогноза.

Далее, используя функцию `train_test_split`, данные разделялись на две части: обучающая выборка (обычно около 80%) и тестовая выборка (около 20%). Такое разделение позволяет оценивать качество модели на независимых от неё данных и избегать переобучения.

На рис. 2 представлена комплексная оценка разработанной модели.

Для оценки качества модели использовались стандартные метрики классификации. Точность (Accuracy) составила 95%, что свидетельствует о высокой общей эффективности алгоритма. Однако эта метрика не отражает баланс между классами, поэтому дополнительно были проанализированы показатели Precision, Recall и F1-Score.

Из представленной комплексной оценки можно увидеть, что в модели высокий показатель точности (Precision для класса «0» составляет

95%), при этом наблюдается высокий уровень сбалансированности модели (F1-Score, являясь гармоническим средним между Precision и Recall, составил 0,96) и полноты проведенного исследования (Recall достиг 96%).

Accuracy: 0.95					
	precision	recall	f1-score	support	
0	0.95	0.96	0.96	2192	
1	0.95	0.93	0.94	1582	
accuracy			0.95	3774	
macro avg	0.95	0.95	0.95	3774	
weighted avg	0.95	0.95	0.95	3774	

Confusion Matrix:
[[2113 79]
[115 1467]]

Предсказание классов и расчет NPS.

Преобразование предсказаний в группы NPS:

Promoters (1): 'satisfied'

Detractors (0): 'neutral or dissatisfied'

Рисунок 2. Показатели эффективности модели

Figure 2. Performance indicators of the model

В результате выполнения работы можно отметить, что для решения задачи прогнозирования наиболее подходящей моделью является случайный лес, представляющий собой ансамбль решающих деревьев. Преимущества случайного леса заключаются в устойчивости к перекосам данных, возможности эффективного использования большого количества признаков и низкой вероятности переобучения. Параметры модели настраивались путём подбора оптимального числа деревьев (`n_estimators`), глубины дерева (`max_depth`) и минимальной численности листьев (`min_samples_leaf`).

Модель показала высокое качество прогноза, с низким уровнем MSE и высоким значением R^2 .

По результатам проведенного исследования можно отметить, что для того, чтобы достичь высокого уровня удовлетворенности клиентов, компаниям следует уделять внимание уровню обслуживания, удобству покупки и использованию, адекватности ценового предложения, персональному подходу, своевременному реагированию на потребности и претензии, информационной поддержке и созданию устойчивого положительного образа бренда.

Считаем, что представленная тема исследования является перспективной для дальнейшего развития и изучения клиентской удовлетворенности с использованием машинного обучения. Следующие действия в исследовании должны включать интеграцию глубоких нейронных сетей для анализа данных, разработку специализированных архитектур и методов оптимизации моделей для увеличения точности и ускорения расчетов.

ЗАКЛЮЧЕНИЕ

Тенденции нового времени обуславливают необходимость перехода от традиционных методов прогнозирования к методам адаптивного прогнозирования и предиктивной аналитики, что в значительной мере повышает точность, скорость и достоверность интерпретируемых данных, которые крайне важны в современной цифровой экономике для повышения конкурентоспособности организации. Кроме того, важно не только фиксировать уровень удовлетворенности клиентов компании, но и своевременно выявлять риски его снижения. Это способствует принятию упреждающих решений, направленных на персонализацию сервиса и адаптацию бизнес-процессов под потребности клиентов.

Представленная в статье методика оценки анализа клиентской удовлетворенности посредством адаптивного моделирования свидетельствует о значимости прогнозирования в вопросах принятия управленческих решений и важности его применения в современных условиях. Такая методология обладает универсальностью и может быть применима в различных сферах деятельности, для целей детального анализа, планирования и формирования обоснованных прогнозов, обеспечивающих повышение качества принимаемых управленческих решений.

*Авторы заявляют об отсутствии
конфликта интересов.*

The authors declare no conflict of interest.

ЛИТЕРАТУРА

1. **Бурнаев Е.В.** Алгоритмические основы предиктивной аналитики в задачах индустриального проектирования. *Информационные процессы*. 2019. Т. 19. № 3. С. 249-270. EDN SBVOQS.
2. **Hastie T., Tibshirani R., Friedman J.** The Elements of Statistical Learning: Data Mining, Inference, and Prediction. https://www.researchgate.net/publication/225734295_The_Elements_of_Statistical_Learning_Data_Mining_Inference_and_Prediction.
3. **Олейникова А.В., Бондарева И.О., Олейников А.А.** Эффективность ETL-процесса для предиктивной аналитики. *Известия Юго-Западного государственного университета*. 2024. Т. 28. № 4. С. 67-85. DOI: 10.21869/2223-1560-2024-28-4-67-85. EDN LDKAXD.
4. **Акимова А.А.** Основные компоненты разработки предиктивной аналитики данных. *Молодёжный вестник Новороссийского филиала Белгородского государственного технологического университета им. В.Г. Шухова*. 2022. Т. 2. № 3(7). С. 64-67. DOI: 10.51639/2713-0576_2022_2_3_64. EDN YIPXKF.
5. **Петрова А.Ф., Петров Е.Н., Касимов Р.А.** Особенности основных инструментов и методов предиктивной аналитики. *Электронные информационные системы*. 2025. № 1(44). С. 101-110. EDN DIVSEI.
6. Инструменты работы с большими массивами данных - технологии для обработки Big Data. <https://developers.sber.ru/help/gigachat-api/big-data>.
7. **Павлова Е.А., Сизова О.В.** Анализ и оптимизация on-line продаж торговой организации. *Известия высших учебных заведений. Серия "Экономика, финансы и управление производством" [Ивэкофин]*. 2024. № 4(62). С. 88-97. DOI: 10.6060/ivecofin.2024624.706 EDN XVZKXI.
8. **Скорик М.А.** Интеллектуальный анализ данных в решении задач предиктивной аналитики. В сб. "Статистика и вызовы современности" Всерос. н.-пр. конференции «День работника статистики». М.: МЭСИ. 2015. С. 475-480. EDN VXVJNH.
9. **Астраханцева И.А., Котенев Т.Е., Горев С.В., Астраханцев Р.Г., Грименицкий П.Н.** Интеграция методов линейной регрессии и случайного леса в системы интеллектуальной поддержки управления криогенными транспортными системами. *Известия высших учебных заведений. Серия «Экономика, финансы и управление производством» [Ивэкофин]*. 2024. № 03(61). С.81-90. DOI: 10.6060/ivecofin.2024613.692. EDN RGESSD.

REFERENCES

1. **Burnaev E.V.** Algorithmic foundations of predictive analytics in industrial engineering design. *Information Processes*. 2019. Vol. 19. N 3. P. 249-270. EDN SBVOQS. (in Russian).
2. **Hastie T., Tibshirani R., Friedman J.** The Elements of Statistical Learning: Data Mining, Inference, and Prediction. https://www.researchgate.net/publication/225734295_The_Elements_of_Statistical_Learning_Data_Mining_Inference_and_Prediction.
3. **Oleynikova A.V., Bondareva I.O., Oleynikov A.A.** The Effectiveness of the ETL Process for Predictive Analytics. *Proceedings of the Southwestern State University*. 2024. Vol. 28. N 4. P. 67-85. DOI: 10.21869/2223-1560-2024-28-4-67-85. EDN LDKAXD. (in Russian).
4. **Akimova A.A.** The main components of predictive data analytics development. *Youth Bulletin of the Novorossiysk branch of the Belgorod State Technological University named after V.G. Shukhov*. 2022. Vol. 2. N 3(7). P. 64-67. DOI: 10.51639/2713-0576_2022_2_3_64. EDN YIPXKF. (in Russian).
5. **Petrova A.F., Petrov E.N., Kasimov R.A.** Predictive analytics – the most common methods and instruments. *Electronic Information Systems*. 2025. N 1(44). P. 101-110. EDN DIVSEI. (in Russian).
6. Tools for working with large data sets - technologies for processing Big Data. <https://developers.sber.ru/help/gigachat-api/big-data>. (in Russian).
7. **Pavlova E.A., Sizova O.V.** Analysis and optimization of online sales of a trade organization. *Ivecofin*. 2024. N 4(62). P. 88-97. DOI: 10.6060/ivecofin.2024624.706 EDN XVZKXI. (in Russian).
8. **Skorik M.A.** Data Mining in Predictive Analytics. "Day of the Statistician" - materials of the All-Russian Scientific and Practical Conference "Statistics and Modern Challenges". Moscow: MESI. 2015. P. 475-480. EDN VXVJNH. (in Russian).
9. **Astrakhtantseva I.A., Kotenev T.E., Gorev S.V., Astrakhtantsev R.G., Grimenitsky P.N.** Integration of linear regression and random forest methods into intelligent support systems for managing cryogenic transport systems. *Ivecofin*. 2024. N 03(61). C.81-90. DOI: 10.6060/ivecofin.2024613.692. EDN CDNSYQ. (in Russian).
10. **Astrakhtantseva I.A., Kotenev T.E., Gorev S.V., Astrakhtantsev R.G., Grimenitsky P.N.** Gradient boosting method in predicting management decisions in the multilayer cryogenic system. *Modern high technologies. Regional application*. 2024. N 2(78). P. 50-58. DOI: 10.6060/snt.20247802.0007. EDN CDNSYQ. (in Russian).

10. Астраханцева И.А., Котенев Т.Е., Горев С.В., Астраханцев Р.Г., Грименицкий П.Н. Метод градиентного бустинга при прогнозировании управленческих решений в многослойной криогенной системе. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 2(78). С. 50-58. DOI: 10.6060/snt.20247802.0007. EDN CDNSYQ.
11. Зимнуров М.Ф., Астраханцева И.А. Методология создания многосвязных структур данных с применением LLM в рабочих проектах. *Современные наукоемкие технологии. Региональное приложение*. 2025. № 1(81). С. 76-83. DOI: 10.6060/snt.20258101.0009. EDN STBGGB.
12. Адаптивные материалы. Большая российская энциклопедия. <https://bigenc.ru/c/adaptivnye-materialy-080ac1>.
13. Бондаренко М.О. Технологии валидации в предиктивной аналитике многомерных данных. В сб. «Инновационное развитие техники и технологий в промышленности» Всерос. научной конференции молодых исследователей с международным участием. М.: РГУ им. А.Н. Косыгина. 2025. С. 80-84. EDN MZLVRG.
14. Рукомин М.А. Обзор ансамблевых моделей предиктивной аналитики и их сравнение с традиционными ML-подходами. *Вестник науки*. 2025. Т. 1. № 8(89). С. 368-373. EDN GJBKYS.
15. Пурыскина В.А. Предиктивная аналитика как современный инструментарий развития бизнеса. *Учет и контроль*. 2025. Т. 1. № 9. С. 37-51. DOI: 10.36871/u.i.k.2025.09.01.005. EDN NVYVPT.
11. Zimnurov M.F., Astrakhantseva I.A. Usage of Large Language Models for building multi-vectored and multi-linked data model of work process. *Modern high technologies. Regional application*. 2025. N 1(81). P. 76-83. DOI: 10.6060/snt.20258101.0009. EDN STBGGB. (in Russian).
12. Adaptive materials. Great Russian Encyclopedia. <https://bigenc.ru/c/adaptivnye-materialy-080ac1>. (in Russian).
13. Bondarenko M.O. Validation technologies in predictive analytics of multidimensional data. *Materials of the All-Russian Scientific Conference of Young Researchers with International Participation «Innovative Development of Industrial Engineering and Technologies»*. Moscow: A.N. Kosygin Russian State University. 2025. P. 80-84. EDN MZLVRG. (in Russian).
14. Rukomin M.A. Review of ensemble models in predictive analytics and their comparison with traditional machine learning approaches. *Bulletin of Science*. 2025. Vol. 1. N 8(89). P. 368-373. EDN GJBKYS. (in Russian).
15. Puryiskina V.A. Predictive analytics as a modern tool for business development. *Accounting and Control*. 2025. Vol. 1. N 9. P. 37-51. DOI: 10.36871/u.i.k.2025.09.01.005. EDN NVYVPT. (in Russian).

Поступила в редакцию 17.01.2026
 Принята к опубликованию 31.01.2026

Received 17.01.2026
 Accepted 31.01.2026