

УДК 004.62

DOI: [10.26102/2310-6018/2026.53.2.018](https://doi.org/10.26102/2310-6018/2026.53.2.018)

Онтологический подход к прогнозированию покупательского поведения пользователей в электронной коммерции

Р.С. Святлов✉

Российский университет дружбы народов, Москва, Российская Федерация

Резюме. Актуальность исследования обусловлена необходимостью повышения точности и интерпретируемости моделей прогнозирования покупательского поведения пользователей интернет-магазинов. Существующие методы машинного обучения демонстрируют высокие показатели качества, однако их эффективность существенно зависит от состава и структуры признакового пространства, которое, как правило, формируется эмпирически и не отражает причинно-следственных связей между пользовательскими действиями. В связи с этим данная работа направлена на разработку метода прогнозирования покупательского поведения, основанного на онтологическом анализе предметной области электронной коммерции. Предложен формализованный подход к описанию сущностей и их взаимосвязей, обеспечивающий системное построение признакового пространства и возможность его масштабирования для различных интернет-магазинов. В качестве инструмента машинного обучения использован алгоритм градиентного бустинга CatBoost, реализованный на данных системы веб-аналитики Яндекс.Метрика. Проведено тестирование на пяти интернет-магазинах различной тематической направленности. Экспериментальные результаты показали устойчивые значения метрик качества (F-мера в 65–83 %), что подтверждает применимость и воспроизводимость предложенного метода. Материалы статьи представляют практическую ценность для разработки интеллектуальных систем поддержки принятия решений в электронной коммерции и могут быть использованы при проектировании масштабируемых аналитических платформ для прогнозирования пользовательской активности и конверсии.

Ключевые слова: машинное обучение, онтологический анализ, анализ поведения пользователей, электронная коммерция, прогнозирование покупательского поведения, интернет-магазины.

Для цитирования: Святлов Р.С. Онтологический подход к прогнозированию покупательского поведения пользователей в электронной коммерции. *Моделирование, оптимизация и информационные технологии*. 2026;14(2). URL: <https://moitvvt.ru/ru/journal/pdf?id=2196> DOI: 10.26102/2310-6018/2026.53.2.018

Ontology-based approach to predicting consumer purchasing behavior in e-commerce

R.S. Svyatov✉

RUDN University, Moscow, the Russian Federation

Abstract. The relevance of this study is determined by the need to improve the accuracy and interpretability of models for predicting consumer purchasing behavior in online stores. Existing machine learning methods demonstrate high performance; however, their effectiveness largely depends on the composition and structure of the feature space, which is typically formed empirically and does not reflect the causal relationships between user actions. This study aims to develop a purchasing behavior prediction method based on an ontological analysis of the e-commerce domain. A formalized approach is proposed for describing entities and their interrelations, providing a systematic construction of the feature space and enabling its scalability across various online stores. The gradient boosting algorithm CatBoost was employed as the machine learning tool, trained on data obtained from the Yandex.Metrica web analytics system. The proposed method was tested on five online stores with different thematic focuses. Experimental results demonstrated stable quality metrics, with F-scores

ranging from 65 % to 83 %, confirming the applicability and reproducibility of the developed approach. The findings have practical significance for the development of intelligent decision support systems in e-commerce and can be utilized in designing scalable analytical platforms for predicting user activity and purchase conversion.

Keywords: machine learning, ontology analysis, user behavior analysis, e-commerce, consumer behavior prediction, online stores.

For citation: Svyatov R.S. Ontology-based approach to predicting consumer purchasing behavior in e-commerce. *Modeling, Optimization and Information Technology*. 2026;14(2). (In Russ.). URL: <https://moitvivr.ru/ru/journal/pdf?id=2196> DOI: 10.26102/2310-6018/2026.53.2.018

Введение

Электронная коммерция развивается с высокой скоростью, порождая огромные объемы информации о действиях пользователей в интернет-магазинах. Каждый визит, просмотр, переход и заказ формируют цифровой след, отражающий индивидуальные особенности покупательского поведения пользователя. Эти данные создают основу для аналитики, ориентированной на прогнозирование намерений клиентов и оценку вероятности совершения покупки. Вместе с ростом объема информации возрастает и сложность ее обработки и интерпретации. Проблема заключается не только в выборе методов и алгоритмов прогнозирования покупательского поведения, но и в выборе характеристик описания поведения пользователей для выявления наиболее ценных и качественных признаков.

Методы машинного обучения демонстрируют высокую результативность при решении задач прогнозирования в электронной торговле, но их качество напрямую зависит от содержания и структуры исходных признаков. В большинстве практических случаев признаки формируются эмпирически, на основе наблюдений и статистических корреляций, что не всегда отражает причинные зависимости внутри предметной области. Отсутствие формализованной логики отбора характеристик приводит к снижению воспроизводимости моделей и ограничивает возможность их переноса на другие платформы.

Современные исследования подтверждают эффективность семантических методов, направленных на структурное описание знаний [1, 2]. Онтологический подход позволяет представить предметную область в виде взаимосвязанных сущностей и свойств, задающих смысловые контексты для признаков. Отдельные работы демонстрируют, что интеграция онтологий в процесс построения моделей машинного обучения способствует повышению интерпретируемости и согласованности признакового пространства [3]. Исследования [4, 5] демонстрируют, что онтологически направленные методы отбора признаков снижают избыточность данных и обеспечивают устойчивость моделей на разнородных выборках.

В сфере интернет-торговли внимание исследователей традиционно сосредоточено на совершенствовании алгоритмов прогнозирования, включая методы градиентного бустинга, ансамблевые модели и нейронные сети [6, 7]. Однако значительно меньшее внимание уделяется тому, как формируются входные признаки и насколько они отражают внутреннюю логику пользовательской активности. Между тем структурирование сущностей, таких как пользователь, визит, товар, событие или источник трафика, и описание связей между ними создают основу для более точных и переносимых прогнозов. Согласно исследованиям [8], использование онтологий делает процесс построения моделей прозрачным, позволяя проследить связь между данными, аналитической обработкой и результатом прогнозирования.

Необходимость интеграции онтологического анализа в задачи прогнозирования покупательского поведения обусловлена стремлением объединить формальное знание о

предметной области с вычислительной мощностью машинного обучения. Такой подход обеспечивает не только повышение точности прогнозов, но и теоретическую обоснованность признаков, которые лежат в основе модели. Целью работы является разработка и экспериментальная проверка метода прогнозирования совершения покупки пользователями интернет-магазинов, основанного на онтологическом описании данных и применении алгоритма градиентного бустинга.

Материалы и методы

Обзор литературы. В последние годы наблюдается активное развитие методов анализа пользовательский данных, направленных на прогнозирование покупательского поведения и повышения результативности бизнеса. Одним из наиболее востребованных направлений является использование алгоритмов машинного обучения для прогнозирования намерений пользователей на основе их сессионной активности, демографических характеристик и транзакционных данных.

Современные исследования в данной области сосредоточены на сравнении различных классификационных подходов, разработке новых алгоритмов и архитектур систем и повышении интерпретируемости получаемых результатов. В Таблице 1 представлен обзор актуальных исследований, отражающих современные подходы к прогнозированию покупательского поведения пользователей интернет-магазинов.

Таблица 1 – Сравнительный анализ существующих исследований
Table 1 – Comparative analysis of existing studies

Исследование	Тип данных	Результаты качества	Используемые алгоритмы	Особенности
[9]	Событийные данные	F-мера = 0,90	Градиентный бустинг, RF	Прогнозирование поведения анонимных пользователей по активности
[10]	Поведенческие логи	Accuracy \approx 0,87	RF, GBM, LogReg	Используются агрегированные показатели активности и корзины
[11]	Событийные данные и покупки	Accuracy = 0,75	RF, XGBoost, LSTM	Сравнение ML и DL для больших наборов пользовательских данных
[12]	Транзакционные данные	Accuracy = 0,915	NB, DT, RF, KNN, SVM, LogReg	Анализ влияния демографических факторов на покупки
[13]	Поведенческие логи	Accuracy = 0,95	FKNN, Fuzzy Logic	Гибридная модель на основе нечеткой логики и машинного обучения
[14]	Поведенческие логи	Accuracy \approx 0,9	Naïve Bayes, Временные ряды	Модель на основе временных последовательностей действий
[15]	Демографические и транзакционные данные	Accuracy = 0,89	SVM, RF	Сравнение интерпретируемости моделей SVM и RF
[16]	Поведенческие логи	–	RF, LogReg	Анализ реакции пользователей на рекламные акции
[17]	Событийные данные	–	RF	Классификация вероятности покупки на основе пользовательских действий
[18]	Сессионные данные	Accuracy > 0,9	ANN, RNN	Глубокое обучение для прогнозирования намерений покупателей

Проведенный анализ исследований показал, что подавляющее большинство работ концентрируется на применении методов машинного обучения для анализа данных о взаимодействии пользователей с интернет-магазинами. В качестве источников данных, как правило, выступают событийные, демографические или транзакционные данные. Наиболее часто используемыми алгоритмами являются случайный лес, градиентный бустинг, нейронные сети и их гибридные модификации. Во многих работах отмечается высокая точность прогнозирования, однако результаты существенно зависят от структуры и качества исходных данных.

Ключевой проблемой рассмотренных исследований является процесс формирования признакового пространства. В большинстве случаев признаки подбираются эмпирически, основываясь на исходных данных, что снижает воспроизводимость моделей и усложняет перенос на другие интернет-магазины из разных предметных областей. Кроме того, такие модели часто демонстрируют высокую точность при ограниченной интерпретируемости, что затрудняет понимание причинно-следственных связей между действиями пользователя и вероятностью совершения покупки.

Таким образом, существующие подходы показывают хорошие результаты на уровне алгоритмов, но недостаточно формализуют процесс описания поведения пользователей. Отсутствие структурированного способа формирования признакового пространства остается существенным ограничением, особенно при необходимости масштабирования и интеграции решений в различные интернет-магазины. В этой связи перспективным направлением исследований является развитие методов, основанных на формализованном описании предметной области и логически согласованном построении признаков, что позволит повысить устойчивость и интерпретируемость моделей прогнозирования покупательского поведения.

Онтологический анализ. Онтология представляет из себя иерархический законопорядок категорий между собой, которым можно формализовать набор определенных терминов рассматриваемой предметной области. В качестве рассматриваемой предметной области выступает интернет-магазин, как организационно-техническая система, в которой технологические, экономические и поведенческие процессы тесно взаимосвязаны. Интернет-магазин включает в себя программно-аппаратную инфраструктуру в виде веб-приложения, базы данных, системы аналитики, интеграции с внешними сервисами и другие компоненты. С другой стороны, интернет-магазин включает в себя организационную часть, выраженную в логистических, маркетинговых и управленческих процедурах, обеспечивающих функционирование интернет-магазина как целостного механизма.

Исследования последних лет подтверждают практическое применение онтологического анализа в задачах, связанных с электронной коммерцией, маркетингом и управлением потребительских данных. Онтология используется для унификации терминов, структурирования сущностей и установления связей между ними. Все это позволяет формировать формализованное представление о знаниях рассматриваемой предметной области.

Так, в ряде исследовательских работ была предпринята попытка формализации предметной области электронной коммерции через разработку специализированных онтологий. В работе [19] предложена модель семантического представления ассортимента интернет-магазина, позволяющая объединять данные каталогов и классифицировать товары. Аналогичный подход реализован в [20], где была разработана онтология для интеграции данных веб-аналитики, включающая в себя такие сущности как события, конверсия, источники трафика и др.

В исследовании [21] построен граф товаров на основе онтологии потребительской электроники, обеспечивающий связь между характеристиками, производителями и пользовательскими отзывами. В работе теоретической направленности [22] предложена онтология потребителей как распределенных сетей, отражающая связь между личностными характеристиками, контекстом взаимодействия и цифровыми следами активности.

С точки зрения системного анализа интернет-магазин рассматривается как многоуровневая система, объединяющая технологический, поведенческий и функциональный уровни. Каждый из уровней описывается собственными категориями, но при этом все уровни взаимосвязаны и влияют друг на друга. Для формализации онтологии выделяется кортеж:

$$O = \langle C, R, D, A \rangle, \quad (1)$$

где C – множество классов (сущностей предметной области), R – множество объектных свойств (отношений между классами), D – множество атрибутивных свойств (характеристик классов), A – множество аксиом и ограничений целостности.

Множество классов C представляет из себя набор типов сущностей, описывающих структуру интернет-магазина и процессы прогнозирования покупательского поведения. На Рисунке 1 представлена структура классов онтологии.



Рисунок 1 – Структура классов онтологии
Figure 1 – Ontology classes structure

Каждая сущность структуры отражает определенный аспект функционирования интернет-магазина. Класс «Пользователь» представляет субъекта взаимодействия с системой, обладающего индивидуальными характеристиками и историей

взаимодействий с интернет-магазином. Класс «Пользовательская_активность» агрегирует поведенческие паттерны, реализуемые через класс «Визит», описывающийся в виде сеанса взаимодействия пользователя с интернет-магазином, характеризующийся временными границами и набором событий. Класс «Пользовательское_событие» фиксирует определенные действия в рамках визита: просмотр товара, добавление в корзину, переход в карточку товара. Класс «Покупка» описывается как целевое событие, завершающее цикл продажи в интернет-магазине.

Класс «Товар» описывает товарную номенклатуру и связанные атрибуты: цену, характеристики, бренд. Класс «Категория_товара» обеспечивает иерархическую классификацию представленных товаров. Классы «Источник_трафика» и «Рекламная_кампания» характеризуют источник трафика и рекламную кампанию, с которой пользователь начал свой визит в интернет-магазине. Классы «Устройство» и «Геолокация» определяют технические параметры и географическое положение пользователя.

Класс «Потребитель» обобщает субъектов потребления, включая индивидов класса «Пользователь». Класс «Потребительское_поведение» формализует поведенческие паттерны, связывающие действия пользователя с аналитическими процессами. Классы организационного уровня включают «Интернет_магазин» как корневую сущность системы, «Торговая_организация» как юридическое лицо владельца, «Организационно-техническая_система» как обобщение инфраструктурных компонентов.

На аналитическом уровне класс «Машинное_обучение» объединяет вычислительные методы и является частью иерархии, включающей «Искусственный_интеллект», «Интеллектуальная_деятельность», «Когнитивные_функции». Класс «Вычислительные_методы» представляет алгоритмическую основу прогнозирования. Класс «Комплекс_технологических_решений» агрегирует программно-технические компоненты системы.

Системный уровень формализуется через классы «Система», «Элемент_системы», «Взаимодействие» и «Цель_системы», отражающие структурные и функциональные аспекты интернет-магазина как целостного механизма. Класс «Модель_системы» обобщает абстрактные представления системы, включая класс «Модель», представляющий обученную прогностическую систему. Класс «Прогнозирование» описывает процесс генерации прогнозов, результатом которого является класс «Прогноз», содержащий оценку вероятности совершения покупки конкретным пользователем. Класс «Опыт» представляет накопленные знания системы, используемые при обучении модели и формировании прогнозов.

Объектные свойства R представляют собой выражения отношений между индивидами различных классов. Множество объектных свойств задает семантические связи между классами онтологии и формирует граф зависимостей, отражающий причинно-следственные связи в рассматриваемой предметной области:

$$R = \{r_1, r_2, r_3, \dots, r_{24}\}, \quad (2)$$

где каждое отношение r_i описывается как функция вида:

$$r_i : C_j \times C_k \rightarrow \{true, false\}. \quad (3)$$

На Рисунке 2 представлен полный перечень сформированных объектных свойств.

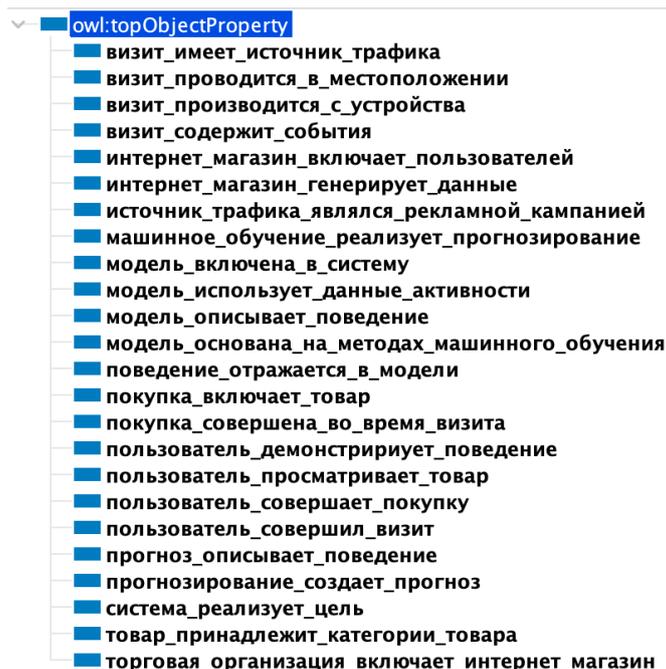


Рисунок 2 – Сформированные объектные свойства классов
Figure 2 – Constructed object properties of classes

На уровне пользовательской активности отношения связывают субъекта взаимодействия с его действиями, формируя временную последовательность визитов и детализируя содержание каждого визита через набор конкретных событий. Транзакционный уровень описывает процесс совершения покупки, связывая пользователя, визит и приобретенные товары в единую цепочку. Контекстные отношения характеризуют внешние условия взаимодействия, включая маркетинговые каналы, технические параметры и географическое положение. Аналитические отношения связывают фактические данные с процессами машинного обучения, формализуя применение прогностической модели к данным пользовательской активности.

Объектные свойства определяют структуру связей между сущностями, но не содержат количественных характеристик этих сущностей. Для описания измеримых параметров классов используются атрибутивные свойства, формирующие основу признакового пространства модели.

Атрибутивные свойства D определяют количественные и качественные характеристики классов. Множество атрибутивных свойств представлено как:

$$D = \{d_1, d_2, d_3, \dots, d_{26}\}, \quad (4)$$

где каждое свойство d_i является функцией вида:

$$d_i : C_j \rightarrow T_i, \quad (5)$$

где $C_j \in C, T_i \in \{\mathbb{R}, \mathbb{N}, String, DateTime\}$.

Полный список атрибутивных свойств рассматриваемой предметной области представлен на Рисунке 3.

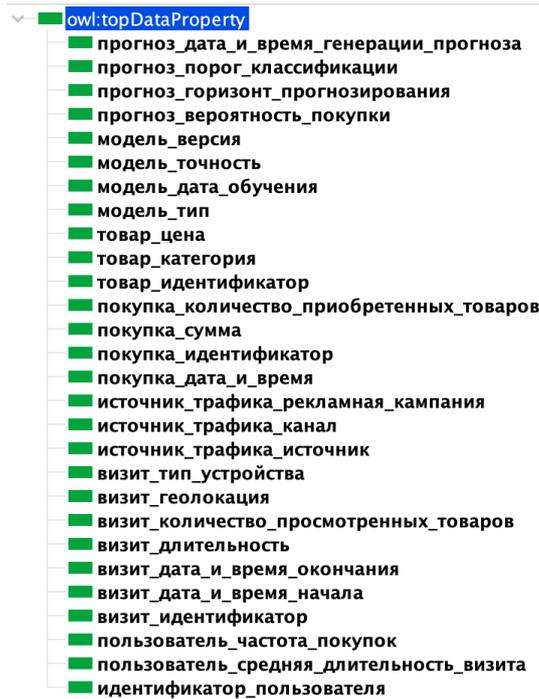


Рисунок 3 – Сформированные атрибутивные свойства классов
Figure 3 – Constructed attribute properties of classes

Свойства класса «Пользователь» характеризуют субъекта взаимодействия через идентификатор, частоту покупок и среднюю длительность визита. Свойства класса «Визит» включают временные границы сеанса, его длительность, количество просмотренных товаров, геолокацию и тип устройства. Свойства класса «Источник_трафика» описывают маркетинговый канал через источник, канал и рекламную кампанию. Свойства класса «Товар» содержат идентификатор, категорию и цену. Свойства класса «Покупка» фиксируют идентификатор транзакции, временную метку, сумму и количество приобретенных товаров.

На аналитическом уровне свойства класса «Модель» описывают тип алгоритма, версию, дату обучения и точность модели. Свойства класса «Прогноз» содержат вероятность покупки, порог классификации, горизонт прогнозирования и временную метку генерации прогноза.

Множество аксиом A определяет логические ограничения, обеспечивающие корректность и непротиворечивость онтологической модели. Аксиомой является утверждение, которое считается истинным и служит предпосылкой для дальнейшего обоснования. В рамках текущего исследования были выделены следующие аксиомы:

$$a_1 : \forall v \in \exists ! \in \text{Пользователь} : r_1(u, v), \quad (6)$$

$$a_2 : \forall p \in \text{Покупка} \exists v \in \text{Визит} : r_{11}(p, v), \quad (7)$$

$$a_3 : \forall v \in \text{Визит} : d_{22}(v) > 0, \quad (8)$$

$$a_4 : \forall p \in \text{Покупка} : d_{13}(p) \geq 0, \quad (9)$$

$$a_5 : \forall m \in \text{Модель} : d_6(m) \in [0, 1], \quad (10)$$

$$a_6 : \forall p \in \text{Покупка} : d_{12}(p) > 0, \quad (11)$$

$$a_7 : \forall v \in \text{Визит} : d_{21}(v) \geq 0, \quad (12)$$

источника данных используются открытые наборы данных, доступные в открытом виде, либо по запросу с определенных ресурсов.

Примерами могут послужить работы [23, 24], где в качестве исходных данных используются сессионные логи с веб-сайта, а также работы [25, 26], использующие открытые наборы данных, например, с площадок, которые проводят соревнования по машинному обучению.

Для демонстрации эффективности применения подхода с формированием признакового пространства на основе онтологического анализа настоящая работа опирается на единый источник данных для разных интернет-магазинов. Упор в сторону единого источника данных подкрепляется разнородностью и доступностью различных наборов данных в открытых источниках. В качестве единого источника данных предлагается использование данных систем веб-аналитики, предоставляющих информацию о действиях пользователей в течение визита пользователя на сайт.

Среди наиболее часто встречаемых систем стоит выделить Яндекс.Метрика и Google Analytics. Данные системы устанавливаются в виде небольшого скрипта кода на сайт, после чего данные о действиях пользователей собираются в едином месте.

В настоящем исследовании предлагается использование веб-аналитической системы Яндекс.Метрика в качестве единого источника данных о действиях пользователей интернет-магазинов. Выбор в пользу данной системы обусловлен ее наличием на более чем 95 % веб-сайтов, что позволяет рассматривать ее как единый источник данных. Дополнительным преимуществом данной системы является наличие бесплатного и открытого API интерфейса, обеспечивающего возможность выгрузки пользовательских данных за произвольные временные интервалы.

Использование системы Google Analytics в качестве единого источника данных сопровождается рядом существенных ограничений. В частности, доступ к произвольным интервалам пользовательских данных на уровне отдельных событий в данной системе возможен только при условии активной интеграции с сервисом Google BigQuery, что требует дополнительных инфраструктурных ресурсов и усложняет процесс внедрения Google Analytics как единого источника данных [27]. Кроме того, такая интеграция не обеспечивает доступ к историческим данным за определенный период, поскольку настроенная интеграция начнет свою работу с момента настройки и не предоставит данные за предшествующие периоды.

Следует также отметить, что в условиях действующих санкционных ограничений использование Google Analytics на территории Российской Федерации демонстрирует устойчивую тенденцию к сокращению. Такая динамика также связана с возможными рисками для бизнесов, использующих Google Analytics, поскольку это касается ответственности за трансграничную передачу персональных данных пользователей.

Альтернативные подходы к сбору данных о действиях пользователей, такие как использование серверных логов или наличие собственных систем сбора данных, не позволяют сформировать единого подхода к сбору и анализу данных. В большинстве случаев компании не осуществляют централизованного сбора данных логов о действиях пользователей, а разработка специализированных модулей сбора данных требует значительных временных и финансовых затрат, что ограничивает практическую применимость подобных подходов.

Для извлечения данных о действиях пользователей используется Logs API, предоставляемый Яндекс.Метрика. Для каждого интернет-магазина извлекается один и тот же набор полей из API Яндекс.Метрика уровня визитов. В Таблице 2 представлен полный список извлекаемых полей из API Яндекс.Метрика.

Таблица 2 – Список выгружаемых полей из API Яндекс.Метрика
Table 2 – List of exported fields from the Yandex.Metrica API

Наименование поля	Тип данных поля	Описание поля
ym:s:visitID	UInt64	Идентификатор визита, уникален в рамках одного года
ym:s:clientID	UInt64	Анонимный идентификатор пользователя в браузере
ym:s:dateTime	DateTime	Дата и время визита
ym:s:pageViews	Int32	Глубина просмотра
ym:s:visitDuration	UInt32	Время на сайте
ym:s:bounce	UInt8	Отказность
ym:s:isNewUser	UInt8	Первый визит посетителя
ym:s:goalsID	Array(UInt32)	Номера целей, достигнутых за данный визит
ym:s:<attribution>TrafficSource	String	Источник трафика
ym:s:purchaseID	Array(String)	Идентификатор покупки. Список всех идентификаторов транзакций для визита
ym:s:purchaseRevenue	Array(Float64)	Общий доход или суммарная ценность транзакции
ym:s:watchIDs	Array(UInt64)	Просмотры, которые были в данном визите
ym:s:deviceCategory	String	Тип устройства. Возможные значения: 1 – десктоп, 2 – мобильные телефоны, 3 – планшеты, 4 – TV

Предложенная конфигурация набора данных является достаточной для построения итогового признакового пространства, так как отражает основные характеристики пользовательской активности в пределах одного визита. Стоит отметить, что выгружаемое поле «Источник трафика» требует указания определенной атрибуции при обращении к API. Модель атрибуции отвечает за принцип определения источника перехода на сайт. В текущем исследовании используется модель атрибуции «Последний значимый переход кросс-девайс», поскольку при анализе результативности бизнеса чаще всего применяется именно эта модель атрибуции.

С целью определения наиболее информативного признакового пространства, обеспечивающего наиболее высокие показатели точности модели, в ранее проведенном исследовании [28] была проведена серия экспериментов. В рамках работы были рассмотрены различные варианты формирования обучающих наборов данных, отличающихся составом используемых признаков.

Всего было сформировано семь подмножеств данных, каждое из которых соответствовало определенной конфигурации признаков или их сочетаний. В частности, были исследованы наборы, включающие только базовые признаки, только событийные данные, а также накопительные характеристики, полученные на основе событийных данных. Отдельное внимание уделялось вариантам со смещением событийных признаков на уровне визитов различной глубины, а также комбинациям базовых и событийных характеристик с различными способами их преобразования.

Результаты экспериментальной оценки показали, что наилучшие значения метрик качества достигаются при использовании базовых признаков в сочетании с событийными данными и их вариациями. Для данного варианта показатель F-меры превышал 70 % во всех рассмотренных категориях интернет-магазинов, что

подтверждает практическую применимость и эффективность выбранного подхода к формированию признакового пространства.

Механизм параметрического формирования временных интервалов анализа данных. Помимо определения единого источника событийных данных пользователей интернет-магазинов, также важным является наличие общего механизма установления временных интервалов для формирования необходимых выборок данных. Для более гибкой возможности извлечения определенных временных окон данных был разработан механизм формирования временных интервалов анализа данных на основе нескольких параметров. В рассмотренных ранее работах временные границы анализа задаются эвристически, либо являются фиксированными для преопределенных наборов данных из открытых источников.

В основе механизма лежит использование трех настраиваемых параметров:

- количество дней, используемых для обучения модели машинного обучения;
- количество дополнительных дней для расчета кумулятивных и агрегированных признаков;
- горизонт прогнозирования, в днях.

На Рисунке 5 представлена параметрическая схема формирования временных интервалов анализа.

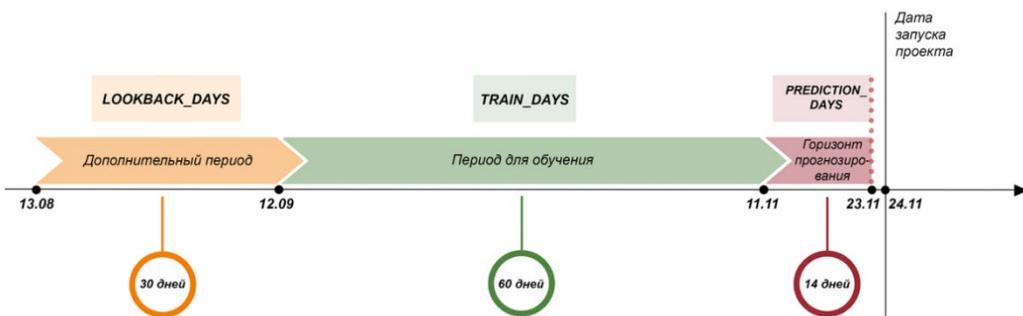


Рисунок 5 – Параметрическая схема формирования временных интервалов анализа
Figure 5 – Parametric scheme for forming temporal analysis intervals

Пусть заданы следующие параметры:

- $T \in \mathbb{N}$ – количество дней для обучения модели (TRAIN_DAYS);
- $L \in \mathbb{N}$ – длина дополнительного периода для расчета кумулятивных признаков (LOOKBACK_DAYS);
- $P \in \mathbb{N}$ – горизонт прогнозирования (PREDICTION_DAYS);
- D_0 – дата запуска проекта.

При этом обязательными ограничениями на параметры являются:

$$T \geq 1, L \geq 0, P \geq 1.$$

Одной из особенностей сервиса Яндекс.Метрика и Logs API для выгрузки данных является отсутствие возможности получения данных в день выгрузки, поскольку данные доступны по предыдущий день включительно. В связи с этим, исторические данные выгружаются по вчерашний день:

$$D_{end} = D_0 - 1. \quad (18)$$

Начало горизонта прогнозирования определяется как период длиной P , непосредственно предшествующий дате запуска:

$$D_{predict_start} = D_0 - P, D_{predict_end} = D_0 - 1. \quad (19)$$

Обучение модели завершается до начала горизонта прогнозирования:

$$D_{train_end} = D_{predict_start} - 1. \quad (20)$$

Начало обучающей выборки формируется следующим образом:

$$D_{train_start} = D_{train_end} - T + 1. \quad (21)$$

Для расчета кумулятивных и агрегированных признаков необходимо выделить дополнительное временное окно, предшествующее дате начала данных для обучения модели:

$$D_{from} = D_{train_start} - L. \quad (22)$$

Итоговые правила формирования временных интервалов представлены в Таблице 3.

Таблица 3 – Правила формирования временных интервалов
 Table 3 – Rules of forming temporal intervals

Назначение	Формула
Начало выгрузки данных	$D_{from} = D_0 - (T + L + P)$
Конец выгрузки данных	$D_0 - 1$
Обучение модели	$[D_{train_start}, D_{train_end}]$
Горизонт прогнозирования	$[D_0 - P, D_0 - 1]$

Таким образом, предложенный механизм обеспечивает строгое разделение периодов формирования признаков, обучения модели и прогнозирования, а также позволяет реализовать единый подход к обработке данных интернет-магазинов независимо от их предметной области и объема накопленной статистики.

Экспериментальный стенд. Для проведения тестирования разработанного подхода был подготовлен экспериментальный стенд для запуска проектов по формированию прогнозов вероятности покупки пользователя интернет-магазинов. В качестве системы управления базами данных (СУБД) использовалась PostgreSQL версии 15.14, используемая для хранения параметров экспериментов, промежуточных результатов и итоговых метрик качества.

Артефакты, формируемые на этапах подготовки данных и обучения моделей машинного обучения, сохранялись в объектном хранилище S3. Оркестрация вычислительных процессов осуществлялась с помощью программного обеспечения Apache Airflow версии 2.9.1, которое позволяет сформировать определенный DAG (Directed acyclic graph). DAG описывается некоторым количеством предустановленных задач (Tasks), которые будут выполнены в процессе работы DAG. На Рисунке 6 представлена схема формирования прогнозов для определенного интернет-магазина в среде Apache Airflow.

Процесс формирования прогнозов включает в себя 9 последовательных этапов с элементами параллельного выполнения задач. На первом этапе выполняется инициализация загрузки параметров конфигурации проекта и модели, извлекаемого из СУБД PostgreSQL. Полученные параметры передаются между задачами посредством механизма XCom. Вторым этапом является выгрузка данных из Logs API Яндекс.Метрика по конкретному интернет-магазину, а также выгрузка информации по доступным целям, настроенными в счетчике Яндекс.Метрика. Выгрузка определенных временных интервалов для анализа осуществляется по принципу, описанному в подразделе «Механизм параметрического формирования временных интервалов анализа данных исследования».

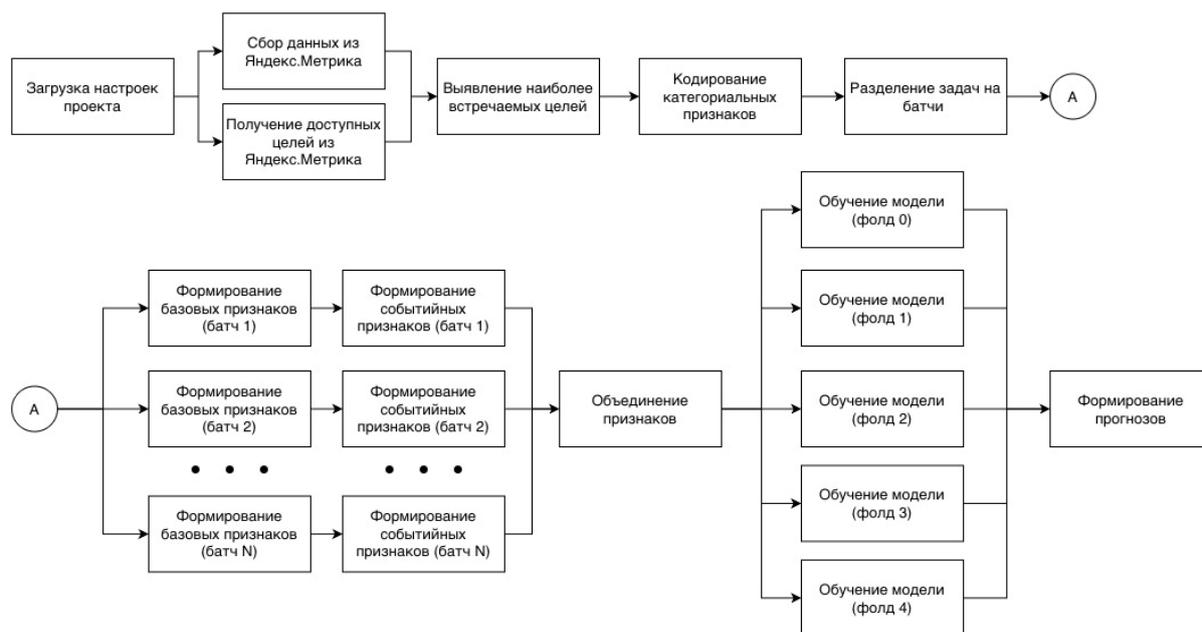


Рисунок 6 – Схема формирования прогнозов для определенного интернет-магазина в среде Apache Airflow

Figure 6 – Scheme for forecast generation for a specific online store in the Apache Airflow environment

На третьем этапе производится анализ полученных данных по доступным целям. Результатом данного этапа является определение наиболее достигаемых целей за определенный временной период для последующего формирования признакового пространства. Четвертый этап включает кодирование категориальных признаков для их численного представления для обучения моделей машинного обучения.

Пятый этап реализует разбиение общего массива задач на N равных частей, где N определяется динамически в зависимости от предустановленного значения переменной в Apache Airflow. В экспериментальной конфигурации данное значение равно 10. Данное разбиение обусловлено необходимостью оптимизации вычислительных ресурсов и минимизации времени обработки задач. Разбиение задач на более мелкие части позволит быстрее обрабатывать задачи обработки данных и формирования признакового пространства.

На шестом этапе для каждого из N батчей последовательно формируются базовые признаки и признаки, основанные на обработке данных о достижениях целей. Все N потоков обрабатываются параллельно при доступности части вычислительных ресурсов. Результаты обработки данных и сформированные признаки сохраняются в S3. Седьмой этап выполняет агрегацию всех сформированных признаков из N батчей в единый набор данных, готовый для обучения моделей машинного обучения.

На восьмом этапе реализуется параллельное обучение пяти моделей с применением кросс-валидации. Каждая из обучаемых моделей выделяет одну из пяти частей набора данных для тестирования, а оставшиеся части использует в процессе обучения. Девятый этап агрегирует результаты всех обученных моделей для формирования финальных прогнозов.

Вычислительная инфраструктура была развернута с использованием сервиса Яндекс.Облако, предоставляющего облачные вычислительные ресурсы. Оркестрация процессов развертывания инфраструктурных элементов экспериментального стенда реализована с помощью Kubernetes. Apache Airflow был развернут при помощи

пакетного менеджера Helm. В рамках проведенного исследования была сформирована группа узлов, включающая шесть вычислительных машин, каждая из которых оснащена 96 ядрами CPU, 576 ГБ оперативной памяти и SSD-накопителем с объемом памяти 64 ГБ.

Проведение экспериментов. Для проведения экспериментов было задействовано 5 интернет-магазинов разной направленности и разных объемов пользователей. В Таблице 4 представлены характеристики интернет-магазинов, отобранных для проведения экспериментов.

Таблица 4 – Параметры интернет-магазинов, участвующих в эксперименте
Table 4 – Parameters of the online stores participating in the experiment

Порядковый номер	Тематика	Уникальные пользователи (мес.)	Количество визитов (мес.)
1	Одежда	224 400	300 700
2	Одежда	175 400	298 500
3	Мебель	256 200	506 100
4	Товары для дома и дачи	1 900 000	2 000 000
5	Магазин обуви	56 700	84 500

Данные таблицы показывают, что для экспериментов были выбраны различные интернет-магазины, никак не связанные между собой. Также стоит отметить разный объем пользователей, что видно по количеству уникальных пользователей в месяц по данным Яндекс.Метрики. Эти показатели позволяют протестировать предложенный подход на неповторяющихся паттернах поведения пользователей.

С помощью экспериментального стенда было запущено 5 проектов со своими входными параметрами. Текущий экспериментальный стенд поддерживает обучение моделей с кросс-валидацией. В качестве количества фолдов было выбрано значение 5, что является стандартом для оценки устойчивости моделей и обеспечивает баланс между скоростью и надежностью валидации. В итоге для каждого проекта было обучено 5 отдельных моделей машинного обучения, каждый из которых обучался на отдельном фолде.

Решение о применении кросс-валидации показало, что оценки качества обучаемых моделей являются неслучайными, что продемонстрировано в полученных результатах. Также стоит отметить, что дополнительно применяется стратификация в кросс-валидации, что позволяет сохранить распределение классов, представленное в исходных наборах данных. В Таблице 5 приведен перечень характеристик экспериментального стенда.

Таблица 5 – Характеристики экспериментального стенда
Table 5 – Experimental setup characteristics

Характеристика	Значение характеристики
Количество дней для расчета кумулятивных значений	30 дней
Количество дней пользовательской активности для обучения модели	60 дней
Горизонт прогнозирования	14 дней
Процент отбора наиболее встречающихся событий для использования	25 %
Количество итераций обучения	2000
Количество итераций перед преждевременной остановкой обучения	450
Скорость обучения	0,01

В рамках исследования для построения модели прогнозирования покупательского поведения пользователей был использован алгоритм градиентного бустинга, зарекомендовавший себя как эффективный метод, демонстрирующий высокие показатели качества в широком спектре задач машинного обучения. В качестве практической реализации данного подхода применялась библиотека CatBoost, разработанная компанией Яндекс.

Для оценки качества прогнозирования покупательского поведения использовались стандартные метрики качества классификации. Поскольку решаемая задача представляет из себя бинарную классификацию, в качестве метрик качества использовались точность, полнота и F-мера. Пусть TP обозначает количество истинно положительных прогнозов, FP – количество ложно положительных прогнозов, а TN – количество истинно отрицательных прогнозов.

Точность (Precision) отражает долю корректно классифицированных положительных объектов среди всех объектов, отнесенных моделью к положительному классу, и определяется следующим образом:

$$Precision = \frac{TP}{TP+FP}. \quad (23)$$

Полнота (Recall) характеризует долю объектов положительного класса, правильно выявленных моделью, и определяется формулой:

$$Recall = \frac{TP}{TP+FN}. \quad (24)$$

Для обеспечения сбалансированной оценки качества моделей в качестве основной метрики использовалась F-мера. Данный показатель представляет собой гармоническое среднее значений точности и полноты, и вычисляется по формуле:

$$F = 2 \cdot \frac{Precision \times Recall}{Precision + Recall}. \quad (25)$$

Результаты

В ходе экспериментального исследования были получены количественные оценки метрик качества обученных моделей машинного обучения для пяти отдельных интернет-магазинов, различающихся тематикой и объемом пользовательской активности. Для каждого интернет-магазина обучение и оценка моделей выполнялись с использованием 5-кратной стратифицированной кросс-валидации, после чего значения метрик усреднялись по всем фолдам. На Рисунке 7 представлены усредненные значения показателей Precision, Recall и F-меры для каждого интернет-магазина.

На данном графике приводятся значения метрик, рассчитанных для положительного класса, соответствующего совершению покупки пользователем. Визуализация метрик именно по положительному классу обусловлена спецификой задачи прогнозирования покупательского поведения, поскольку значения метрик качества по Precision и Recall для отрицательного класса превышали 99 % по всем интернет-магазинам и фолдам, что связано с выраженной несбалансированностью классов. Таким образом, наибольший интерес с точки зрения оценки качества моделей представляет способность корректно прогнозировать именно факт покупки.

Представленные результаты демонстрируют различное соотношение показателей точности и полноты в зависимости от интернет-магазина. Значения Precision варьируются в пределах от 44,2 % до 64,6 %, в то время как значения Recall находятся в диапазоне от 24,2 % до 70,2 %. Несмотря на наблюдаемый разброс отдельных метрик, значения общей F-меры для всех интернет-магазинов остаются на уровне,

превышающем 65 %, достигая максимального значения 83,3 % для интернет-магазина обуви.

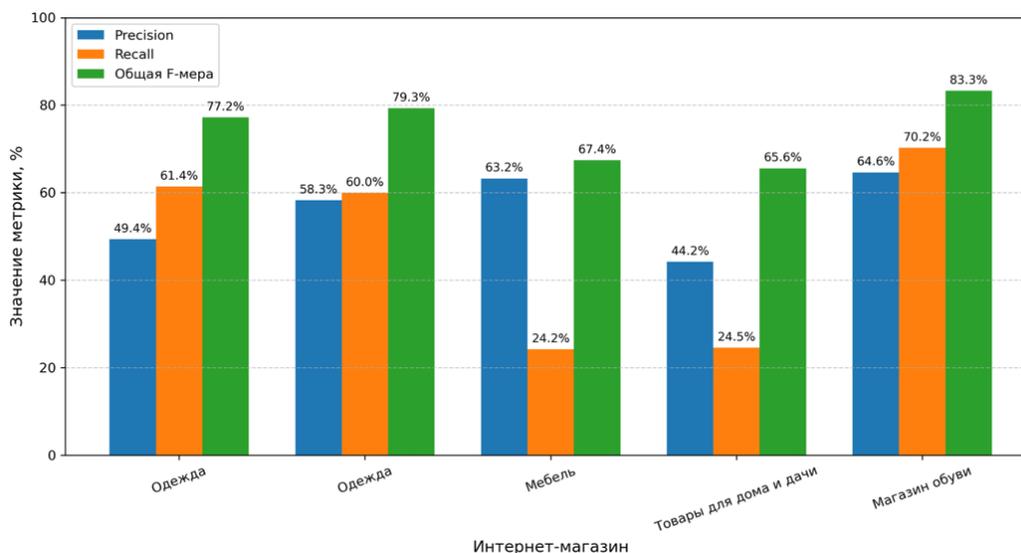


Рисунок 7 – Усредненные значения показателей Precision, Recall и F-меры для каждого интернет-магазина

Figure 7 – Average Precision, Recall and F-score values for each online store

В дополнение к усредненным значениям метрик на Рисунке 8 представлены значения общей F-меры, полученные для каждого интернет-магазина на отдельных фолдах кросс-валидации.

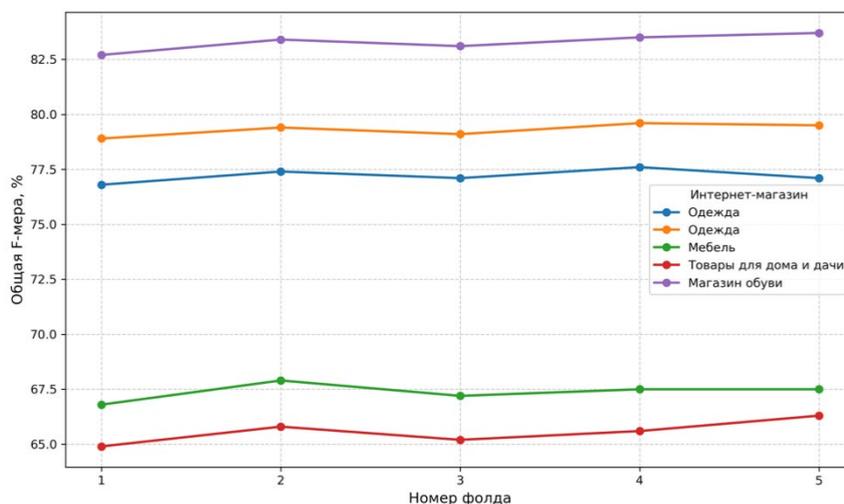


Рисунок 8 – Значения общей F-меры по каждому из фолдов по каждому интернет-магазину

Figure 8 – Overall F-score values across cross-validation folds for each online store

Данный график иллюстрирует изменение показателя качества в зависимости от конкретного разбиения данных на обучающие и валидационные подвыборки. Использование кросс-валидации в рамках экспериментов было направлено на проверку устойчивости получаемых оценок качества и исключение влияния случайного выбора обучающей выборки. Как видно из представленных результатов, значения общей F-меры для каждого интернет-магазина демонстрируют незначительные колебания при

переходе от одного фолда к другому. Разброс значений не превышает нескольких процентных пунктов, что свидетельствует о стабильности работы обученных моделей.

Полученные результаты означают то, что обученные модели способны формировать устойчивые и воспроизводимые прогнозы покупательского поведения пользователей для различных интернет-магазинов, отличающихся тематикой и объемом данных. Значения общей F-меры подтверждают приемлемое качество классификации и демонстрируют практическую применимость предложенного подхода в условиях реальных пользовательских данных.

Обсуждение

Результаты экспериментов подтверждают эффективность применения онтологического подхода при прогнозировании покупательского поведения пользователей интернет-магазинов. Формализованное описание предметной области позволило сформировать структурированное признаковое пространство, обеспечившее устойчивое качество классификации на данных пяти различных интернет-магазинов. Средние значения F-меры превышают 65 %, достигая 83,3 % для отдельных случаев, что подтверждает применимость предложенной модели в условиях разнородных данных и различных пользовательских сценариев.

Сопоставление полученных результатов с работами других авторов показывает, что разработанный метод демонстрирует соизмеримые или более стабильные показатели точности при меньшей зависимости от структуры исходных данных. Большинство существующих исследований используют эмпирические признаки и ориентированы на конкретные наборы данных, что ограничивает переносимость моделей. В предложенном решении данное ограничение устранено за счет использования онтологически сформированного набора признаков, отражающего причинно-следственные связи между действиями пользователей, параметрами визитов и вероятностью совершения покупки.

Стабильность метрик в рамках кросс-валидации и незначительные колебания значений F-меры между фолдами подтвердило устойчивость обученных моделей и отсутствие переобучения. Применение стратифицированной кросс-валидации позволило сохранить пропорции классов и достоверно оценить способность модели выявлять готовность пользователей к совершению покупки. Анализ показал, что наибольшая точность прогнозирования наблюдается для магазинов с относительно ограниченным ассортиментом и стабильными паттернами поведения пользователей, тогда как в выборках с высокой вариативностью сценариев поведение модели остается предсказуемым и статистически согласованным.

Использование веб-аналитической системы Яндекс.Метрика в качестве единого источника данных доказало возможность построения единой архитектуры прогнозирования без привязки к внутренним структурам конкретных интернет-магазинов. Разработанный механизм параметрического формирования временных интервалов обеспечил корректное разделение обучающих и прогнозных периодов в зависимости от входных параметров.

Полученные результаты демонстрируют, что онтологический анализ предметной области повышает согласованность признакового пространства и интерпретируемость прогностических моделей. Такой подход обеспечивает формализованную связь между пользовательскими действиями и результатами машинного обучения, что отличает его от существующих методов, опирающихся на эвристический выбор характеристик. Внедрение онтологического подхода формирует основу для построения масштабируемых и интерпретируемых систем прогнозирования в электронной коммерции.

Заключение

В работе предложен метод прогнозирования покупательского поведения пользователей интернет-магазинов, основанный на онтологическом описании предметной области и формализованном построении признакового пространства для моделей машинного обучения. Онтологический анализ позволил структурировать сущности и взаимосвязи, описывающие процессы электронной коммерции, что обеспечило согласованность и интерпретируемость входных данных.

Разработанный подход реализован на данных системы веб-аналитики Яндекс.Метрика и протестирован на пяти интернет-магазинах различной направленности. Экспериментальные результаты показали устойчивые значения метрик качества, при этом средняя F-мера превышала 65 %, достигая максимального значения 83,3 %. Стабильность метрик на разных выборках подтверждает универсальность предложенного решения и его применимость в условиях разнородных пользовательских сценариев.

В отличие от традиционных методов, использующих эмпирический выбор признаков, предложенный подход обеспечивает формализованную логику их формирования, что снижает зависимость моделей от структуры исходных данных и упрощает перенос решений между различными интернет-магазинами.

Полученные результаты подтверждают эффективность интеграции онтологического анализа в процесс машинного обучения при решении задач прогнозирования покупательского поведения. Дальнейшие исследования целесообразно направить на автоматизацию построения онтологий и разработку адаптивных моделей, способных динамически обновлять структуру признаков при изменении пользовательской активности и контекста функционирования интернет-магазина.

СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Sikelis K., Tsekouras G.E., Kotis K.I. Ontology-Based Feature Selection: A Survey. arXiv. URL: <https://doi.org/10.48550/arXiv.2104.07720> [Accessed 18th January 2026].
2. Vicient C., Sánchez D., Moreno A. An Automatic Approach for Ontology-Based Feature Extraction from Heterogeneous Textual Resources. *Engineering Applications of Artificial Intelligence*. 2013;26(3):1092–1106. <https://doi.org/10.1016/j.engappai.2012.08.002>
3. Di Noia T., Magarelli C., Maurino A., Palmonari M., Rula A. Using ontology-based data summarization to develop semantics-aware recommender systems. In: *The Semantic Web: 15th International Conference, ESWC 2018, 03–07 June 2018, Heraklion, Crete, Greece*. Cham: Springer; 2018. P. 128–144. https://doi.org/10.1007/978-3-319-93417-4_9
4. Lu S., Ye Y., Tsui R., et al. Domain Ontology-based Feature Reduction for High Dimensional Drug Data and its Application to 30-Day Heart Failure Readmission Prediction. In: *9th IEEE International Conference on Collaborative Computing: Networking, Applications and Worksharing, 20–23 October 2013, Austin, TX, USA*. IEEE; 2013. P. 478–484. <https://doi.org/10.4108/icst.collaboratecom.2013.254124>
5. Abdollahi M., Gao X., Mei Y., Ghosh Sh., Li J. An Ontology-based Two-Stage Approach to Medical Text Classification with Feature Selection by Particle Swarm Optimisation. In: *2019 IEEE Congress on Evolutionary Computation, 10–13 June 2019, Wellington, New Zealand*. IEEE; 2019. P. 119–126. <https://doi.org/10.1109/CEC.2019.8790259>
6. Kühl N., Mühlthaler M., Goutier M. Supporting customer-oriented marketing with artificial intelligence: automatically quantifying customer needs from social media. *Electronic Markets*. 2020;30(2):351–367. <https://doi.org/10.1007/s12525-019-00351-0>

7. Heilman C.M., Kaefer F., Ramenofsky S.D. Determining the appropriate amount of data for classifying consumers for direct marketing purposes. *Journal of Interactive Marketing*. 2003;17(3):5–28. <https://doi.org/10.1002/dir.10057>
8. Kotis K.I., Vouros G.A., Spiliotopoulos D. Ontology engineering methodologies for the evolution of living and reused ontologies: status, trends, findings and recommendations. *The Knowledge Engineering Review*. 2020;35. <https://doi.org/10.1017/S026988892000065>
9. Wen Zh., Lin W., Liu H. Machine-Learning-Based Approach for Anonymous Online Customer Purchase Intentions Using Clickstream Data. *Systems*. 2023;11(5). <https://doi.org/10.3390/systems11050255>
10. Hesvindrati N., Aminuddin A., Mahadhni J., Pambudi A., Sudaryatno B. Behavior-Based Purchase Intent Prediction in E-Commerce: A Machine Learning Approach. *International Journal of Current Science Research and Review*. 2025;8(8):3970–3980. <https://doi.org/10.47191/ijcsrr/V8-i8-03>
11. Liu D., Huang H., Zhang H., Luo X., Fan Zh. Enhancing customer behavior prediction in e-commerce: A comparative analysis of machine learning and deep learning models. *Applied and Computational Engineering*. 2024;55(1):181–195. <https://doi.org/10.54254/2755-2721/55/20241475>
12. Abhichandani D., Vadrevu N.R.T., Doshi P., Shrivastava Sh. Predicting Online Purchases Using Six Machine Learning Models Based on Customer Demographics. In: *2025 6th International Conference on Data Intelligence and Cognitive Informatics (ICDICI), 09–11 July 2025, Tirunelveli, India*. IEEE; 2025. P. 1787–1792. <https://doi.org/10.1109/icdici66477.2025.11135228>
13. Ayyadapu A.K.R., Saini P., Gupta P., et al. Fuzzy Logic and Machine Learning Hybrid Model for Influencing Consumer Purchasing Behavior in E-Commerce. In: *2025 International Conference on Computing Technologies & Data Communication, 04–05 July 2025, HASSAN, India*. IEEE; 2025. P. 1–6. <https://doi.org/10.1109/icctdc64446.2025.11158906>
14. Li H. Research on Consumer Behavior Prediction Based on E-commerce Data Analysis. *BCP Business & Management*. 2023;49:106–110. <https://doi.org/10.54691/bcpbm.v49i.5411>
15. Htar T.T., Zaw M.M. Predicting Consumer Purchasing Behavior Using SVM and Random Forest Classification Methods. *International Journal of Scientific Research in Engineering and Management*. 2025;9(8). <https://doi.org/10.55041/ijrem51727>
16. Huang W. Analysis of Promotional Online Shopping Behavior Based on Machine Learning. *Highlights in Science, Engineering and Technology*. 2023;56:65–72. <https://doi.org/10.54097/hset.v56i.9817>
17. Usha U.M., Swamy K.P.N. Anticipatory Modeling of Product Purchases. *International Journal of Advanced Research in Science, Communication and Technology*. 2024;4(1):137–143. <https://doi.org/10.48175/ijarsct-19117>
18. Chaudhuri N., Gupta G., Vamsi V., Bose I. On the platform but will they buy? Predicting customers' purchase behavior using deep learning. *Decision Support Systems*. 2021;149. <https://doi.org/10.1016/j.dss.2021.113622>
19. Bhutani P., Baranwal Sh.K., Jain S. Semantic Framework for Facilitating Product Discovery. In: *ACI'21: Workshop on Advances in Computational Intelligence at ISIC 2021, 25–27 February 2021, Delhi, India*. 2021. P. 30–36.
20. García M. del M.R., García-Nieto J., Aldana-Montes J.F. An ontology-based data integration approach for web analytics in e-commerce. *Expert Systems with Applications*. 2016;63:20–34. <https://doi.org/10.1016/j.eswa.2016.06.034>

21. Kim H. Developing a Product Knowledge Graph of Consumer Electronics to Manage Sustainable Product Information. *Sustainability*. 2021;13(4). <https://doi.org/10.3390/su13041722>
22. Preece Ch., Rojas Gaviria P. An ontology of consumers as distributed networks: a question of cause and effect. *Journal of Marketing Management*. 2024;40(7-8):628–634. <https://doi.org/10.1080/0267257X.2024.2346010>
23. Esmeli R., Bader-El-Den M., Abdullahi H. Towards early purchase intention prediction in online session based retailing systems. *Electronic Markets*. 2020;31:697–715. <https://doi.org/10.1007/s12525-020-00448-x>
24. Liu Zh., Zhang Y., Abedin M.Z., et al. Profit-driven fusion framework based on bagging and boosting classifiers for potential purchaser prediction. *Journal of Retailing and Consumer Services*. 2024;79. <https://doi.org/10.1016/j.jretconser.2024.103854>
25. Zhang W., Wang M. An improved deep forest model for prediction of e-commerce consumers' repurchase behavior. *PLoS ONE*. 2021;16(9). <https://doi.org/10.1371/journal.pone.0255906>
26. Zhou Sh., Hudin N.S. Advancing e-commerce user purchase prediction: Integration of time-series attention with event-based timestamp encoding and Graph Neural Network-Enhanced user profiling. *PLoS ONE*. 2024;19(4). <https://doi.org/10.1371/journal.pone.0299087>
27. Chauleva B., Capeska Bogatinoska D., Karadimce A. Optimizing Customer Journey through Advanced Analytics Techniques over Google Analytics 4 Data in Google BigQuery. *WSEAS Transactions On Computers*. 2024;23:336–346. <https://doi.org/10.37394/23205.2024.23.33>
28. Святлов Р.С. Прогнозирование покупательского поведения пользователей интернет-магазинов на основе событийных данных. *Моделирование, оптимизация и информационные технологии*. 2025;13(4). <https://doi.org/10.26102/2310-6018/2025.51.4.064>
Svyatov R.S. Forecasting e-commerce user purchase behavior based on event data. *Modeling, Optimization and Information Technology*. 2025;13(4). (In Russ.). <https://doi.org/10.26102/2310-6018/2025.51.4.064>

ИНФОРМАЦИЯ ОБ АВТОРЕ / INFORMATION ABOUT THE AUTHOR

Святлов Роман Сергеевич, аспирант, **Roman S. Svyatov**, Postgraduate, RUDN Российский университет дружбы народов, University, Moscow, the Russian Federation. Москва, Российская Федерация.
e-mail: romasvyatov@yandex.ru
ORCID: [0009-0009-0322-1443](https://orcid.org/0009-0009-0322-1443)

Статья поступила в редакцию 26.01.2026; одобрена после рецензирования 23.02.2026; принята к публикации 26.02.2026.

The article was submitted 26.01.2026; approved after reviewing 23.02.2026; accepted for publication 26.02.2026.