Нестеров А.В. Оптимизация продуктовых решений на основе предиктивной аналитики и машинного обучения// Международный журнал информационных технологий и энергоэффективности. – 2026. – Т. 11 № 6 (68) Ч. 1 с. 62–69

Международный журнал информационных технологий и энергоэффективности

Сайт журнала:
http://www.openaccessscience.ru/index.php/ijcse/



УДК 004.8:658.5

ОПТИМИЗАЦИЯ ПРОДУКТОВЫХ РЕШЕНИЙ НА ОСНОВЕ ПРЕДИКТИВНОЙ АНАЛИТИКИ И МАШИННОГО ОБУЧЕНИЯ

Нестеров А.В., Дешко И.П. (научный руководитель)
ФГБОУ ВО «МИРЭА - РОССИЙСКИЙ ТЕХНОЛОГИЧЕСКИЙ УНИВЕРСИТЕТ», Москва, Россия (119454, г. Москва, пр-т Вернадского, д. 78, стр. 4), e-mail: sanchotar@gmail.com

В статье рассматриваются методы машинного обучения для оптимизации решений в продуктовом менеджменте. Проведён анализ ключевых задач продуктовой аналитики, где применение предиктивных моделей даёт наибольший эффект: прогнозирование оттока пользователей, оценка пожизненной ценности клиента, оптимизация воронки конверсии. Обоснованы требования к качеству данных и объяснимости моделей. Предложен подход к интеграции прогнозных сигналов в операционные процессы управления продуктом.

Ключевые слова**:** Продуктовый менеджмент, машинное обучение, предиктивная аналитика, прогнозирование оттока, пожизненная ценность клиента, оптимизация конверсии.

OPTIMIZATION OF PRODUCT DECISIONS BASED ON PREDICTIVE ANALYTICS AND MACHINE LEARNING

Nesterov A.V., Deshko I.P. (Academic Supervisor)
MIREA - RUSSIAN TECHNOLOGICAL UNIVERSITY, Moscow, Russia (119454, Moscow, avenue Vernadsky, 78, b. 4), e-mail: sanchotar@gmail.com

This paper examines machine learning methods for optimizing decisions in product management. An analysis is conducted of key product analytics tasks where predictive models yield the greatest effect: churn prediction, customer lifetime value estimation, and conversion funnel optimization. Requirements for data quality and model explainability are substantiated. An approach to integrating predictive signals into operational product management processes is proposed.

Keywords: Product management, machine learning, predictive analytics, churn prediction, customer lifetime value, conversion optimization.

Современный продуктовый менеджмент функционирует в условиях экспоненциального роста данных о поведении пользователей, но при этом большинство решений о развитии продукта по-прежнему принимается на основе запаздывающих метрик и качественных гипотез. Традиционные подходы, такие как анализ исторических данных, опросы пользователей и экспертные оценки, неизбежно страдают от субъективности и инерционности – они показывают, что уже произошло, но не позволяют оперативно реагировать на изменения в реальном времени. Согласно аналитическим обзорам, компании, внедряющие предиктивную аналитику в процессы управления продуктом, сокращают время реакции на изменения рыночной ситуации на 30–40% и повышают точность прогнозов ключевых показателей до 75–85% при правильно настроенных моделях машинного обучения [1, 2]. При этом важно понимать, что сам по себе прогноз – это лишь вероятностная оценка будущего, а ценность он приобретает только тогда, когда становится основой для конкретных управленческих

действий. Однако между получением аналитического инсайта и его операциональным применением в продуктовых решениях сохраняется значительный разрыв, который в данной работе предлагается сокращать за счёт интеграции прогнозных моделей непосредственно в контуры управления продуктом. Речь идёт не просто о добавлении «умных» дашбордов, а о создании замкнутого цикла, в котором модель не только предсказывает, но и инициирует действия, а затем оценивает их эффективность для последующего обучения.

Объектом исследования выступают процессы принятия решений в продуктовом менеджменте, связанные с управлением пользовательским опытом, оптимизацией воронок и планированием функциональности. Предметом исследования являются методы машинного обучения и предиктивной аналитики, применимые для повышения обоснованности и скорости продуктовых решений. Целью работы является выявление наиболее эффективных сценариев применения прогнозных моделей в продуктовой аналитике и формулирование требований к их интеграции в управленческий контур. Дополнительная задача – показать, какие организационные и технические барьеры возникают на пути внедрения таких моделей в реальных продуктовых командах, и предложить способы их преодоления. В отличие от исследований, фокусирующихся исключительно на точности алгоритмов, в данной работе акцент сделан на практической применимости и встраиваемости моделей в существующие процессы.

Продуктовый менеджмент как дисциплина традиционно опирается на цикл «гипотеза – эксперимент – анализ – решение». Этот цикл может быть существенно ускорен, если вместо ручного анализа исторических данных использовать модели машинного обучения, которые автоматически выявляют паттерны и формируют прогнозы. Например, вместо того чтобы раз в неделю смотреть отчёт о падении конверсии и начинать расследование причин, команда может получать автоматические сигналы об аномалиях в реальном времени с указанием наиболее вероятных факторов. Более того, модель может не только сигнализировать о проблеме, но и предлагать (или даже автоматически применять) корректирующие действия – изменить параметры A/B-теста, запустить коммуникацию с определённым сегментом пользователей или скорректировать приоритеты в бэклоге. В современной практике выделяются три ключевые задачи, где предиктивные модели показывают наибольшую эффективность: прогнозирование оттока пользователей (churn prediction), оценка пожизненной ценности клиента (customer lifetime value, LTV) и оптимизация воронки конверсии (conversion funnel optimization). Каждая из этих задач имеет свою специфику и требует различных подходов к построению моделей, различной частоты переобучения и разных стратегий валидации. Выбор именно этих трёх задач обусловлен тем, что они охватывают весь жизненный цикл взаимодействия пользователя с продуктом – от привлечения до удержания – и при этом имеют прямое влияние на ключевые бизнес-метрики.

Прогнозирование оттока является одной из наиболее изученных областей применения машинного обучения в управлении продуктом. Основная задача – по историческим данным о поведении пользователя предсказать вероятность того, что он прекратит использование продукта в заданный временной горизонт (обычно 7, 14 или 30 дней). Для построения таких моделей чаще всего используются логистическая регрессия, случайный лес и градиентный бустинг (XGBoost, LightGBM). Каждый из этих методов имеет свои преимущества: логистическая регрессия даёт высокую интерпретируемость, случайный лес устойчив к выбросам, а градиентный бустинг, как правило, обеспечивает наилучшую точность. Как

отмечается в исследованиях, градиентный бустинг обеспечивает высокую точность прогнозирования, позволяя выявлять сложные паттерны, которые однофакторный анализ может пропустить [3]. Качественный прогноз оттока требует не только учёта частоты и давности действий пользователя (recency, frequency, monetary – RFM-метрики), но и анализа поведенческих паттернов: снижение критических действий, изменение маршрутов в продукте, негативные сигналы в обратной связи. Например, если пользователь, который ранее ежедневно выполнял целевое действие, перестал заходить в приложение на протяжении пяти дней подряд, это более сильный сигнал, чем простое снижение частоты. Аналогично, если пользователь оставил негативный отзыв в поддержке или в социальных сетях, это также повышает вероятность оттока. При этом точность модели на тестовой выборке обычно составляет 70–85% в зависимости от качества исходных данных и выбранных признаков. Важно, что прогноз оттока сам по себе не является решением – он должен быть связан с набором удерживающих действий (таргетированная коммуникация, предложение скидки, изменение пользовательского опыта). В этом заключается ключевой принцип управляемой предиктивности: модель даёт сигнал, но действие должно быть определено отдельной политикой с учётом контекста и возможных побочных эффектов. Например, слишком агрессивные удерживающие кампании могут раздражать пользователей и приводить к обратному эффекту. Поэтому политика действий должна включать не только правила «если риск высок, то сделать X», но и механизмы A/B-тестирования самих удерживающих вмешательств.

Оценка пожизненной ценности клиента представляет собой более сложную прогнозную задачу, поскольку LTV зависит не только от поведения пользователя, но и от внешних факторов, включая сезонность, конкурентную среду и макроэкономические условия. Традиционные методы RFM-анализа дают лишь приблизительную оценку прошлой ценности, тогда как машинное обучение позволяет строить прогнозы будущей LTV на основе временных рядов поведения. Для этой цели применяются регрессионные модели, модели на основе скрытых марковских процессов и, в последнее время, нейросетевые подходы. Каждый метод имеет свою область применения: простые регрессии хороши для стабильных продуктов с предсказуемым поведением, нейросети требуют больших объёмов данных, но способны улавливать нелинейные зависимости. Исследования показывают, что градиентный бустинг и нейросетевые архитектуры (LSTM) существенно повышают точность прогнозов LTV по сравнению с линейной регрессией, достигая значений R^2 в диапазоне 0,94 при правильно подобранных гиперпараметрах и достаточном объёме данных [4]. Ключевая особенность прогнозирования LTV в контексте продуктового менеджмента заключается в том, что этот показатель является производным от множества продуктовых решений: изменение интерфейса, добавление или удаление функций, ценовая политика. Поэтому модель LTV должна переобучаться при каждом существенном изменении продукта, что накладывает требования к автоматизации циклов переобучения. В противном случае прогнозы быстро устаревают и вводят в заблуждение команду разработки. Например, если компания запускает новую платную подписку, то старая модель, обученная на данных до этого изменения, будет систематически занижать прогнозируемый LTV, поскольку не учитывает новый источник монетизации. Следовательно, необходимо настроить автоматическое обнаружение дрейфа данных и триггеры для переобучения – например, после каждого крупного релиза или еженедельно, если объём новых пользователей достаточно велик.

Оптимизация воронки конверсии – задача, в которой машинное обучение может применяться как для диагностики узких мест, так и для формирования рекомендаций по их устранению. Традиционные инструменты аналитики (например, построение воронок и анализ падения конверсии между этапами) показывают, где происходит потеря пользователей, но не объясняют почему. Модели машинного обучения способны заглянуть глубже: они могут анализировать сотни потенциальных факторов одновременно, выявляя те, которые статистически значимо коррелируют с отказом от перехода на следующий этап. Методы машинного обучения, в частности кластеризация и деревья решений, позволяют сегментировать пользователей по паттернам поведения и выявлять скрытые факторы, влияющие на переход к следующему этапу. Например, модель может обнаружить, что пользователи, пришедшие из определённого канала трафика, с высокой вероятностью покидают воронку на этапе регистрации из-за сложности формы, тогда как для других каналов этот фактор незначителен. Такой инсайт напрямую указывает на конкретное продуктовое решение: упростить форму регистрации именно для проблемного сегмента или изменить канальную стратегию. Более того, с помощью деревьев решений можно построить интерпретируемые правила – например, «если пользователь пришёл из канала X и время заполнения формы превышает 30 секунд, то вероятность конверсии на следующем шаге составляет менее 10%». Эти правила могут быть напрямую переданы команде разработки для реализации точечных улучшений. Дальнейшее развитие этого подхода – использование моделей для персонализации воронки в реальном времени, когда каждый следующий этап адаптируется под прогнозируемую вероятность успеха конкретного пользователя. Например, если модель предсказывает, что данный пользователь с высокой вероятностью бросит заполнение длинной анкеты, система может динамически сократить анкету или предложить альтернативный путь – войти через социальную сеть.

Однако применение машинного обучения в продуктовом менеджменте сталкивается с рядом системных ограничений, которые необходимо учитывать при проектировании соответствующих систем. Эти ограничения носят не только технический, но и организационный характер. Первое ограничение – качество и полнота данных. Модели машинного обучения критически зависят от того, насколько полно в данных отражены все значимые факторы. Если команда продукта не собирает события о неудачных попытках выполнения действия (например, ошибки валидации формы), то модель не сможет предсказывать их влияние на конверсию. Поэтому внедрение предиктивной аналитики должно начинаться с аудита событийной модели и обеспечения сбора всех релевантных сигналов. На практике это означает тесное взаимодействие продуктовых менеджеров, аналитиков и разработчиков – необходимо определить, какие именно пользовательские действия и их исходы имеют значение для прогнозирования. Второе ограничение – объяснимость решений. В отличие от рекламной оптимизации, где допустима «чёрная коробка» при условии положительной динамики метрик, в управлении продуктом менеджеры должны понимать, почему модель сделала тот или иной прогноз, чтобы принять обоснованное решение о действии. Это требует использования методов объяснимого искусственного интеллекта (XAI), таких как SHAP-значения или LIME, а также прозрачных, интерпретируемых моделей (например, деревья решений вместо глубоких нейросетей) там, где это возможно без существенной потери точности. Без объяснимости менеджеры не смогут доверять модели и, следовательно, не будут использовать её рекомендации в критически

важных решениях. Третье ограничение – динамическая нестабильность поведенческих паттернов. Пользовательское поведение меняется вместе с продуктом, и модель, обученная на данных до релиза новой функции, может давать систематически ошибочные прогнозы после него. Это требует организации непрерывного мониторинга качества моделей и автоматизированного переобучения при обнаружении дрейфа концепции (concept drift). Например, если после обновления дизайна главного экрана модель начинает ошибаться в прогнозах конверсии, необходимо либо переобучить её на новых данных, либо временно откатить использование модели до выяснения причин.

Сравнительный анализ существующих подходов к интеграции предиктивной аналитики в продуктовый менеджмент позволяет выделить три уровня зрелости таких систем. На первом уровне модели используются для пассивной отчётности: дашборд показывает прогнозы оттока или LTV, но решения принимаются менеджером вручную. Этот уровень характерен для большинства компаний, которые только начинают внедрять машинное обучение в продуктовую аналитику. На втором уровне модели встроены в процессы поддержки решений: система автоматически формирует рекомендации (например, «включить удерживающую кампанию для сегмента X») и предоставляет обоснование, но финальное действие утверждает человек. Такой подход позволяет сохранить контроль со стороны менеджера, но при этом существенно ускоряет принятие решений, так как аналитическая работа уже выполнена моделью. На третьем уровне реализуется замкнутый контур управления: прогнозная модель напрямую связана с исполнительными механизмами (автоматическая отправка пуш-уведомлений, изменение параметров A/B-теста, перераспределение ресурсов на разработку), при этом все действия фиксируются для последующего измерения их инкрементального эффекта. Третий уровень требует высокой степени доверия к модели и наличия предохранителей – лимитов на автоматические изменения, возможности быстрой отмены действий, а также механизмов для измерения эффекта от каждого автоматического решения. Большинство современных платформ продуктовой аналитики находятся на первом или переходном ко второму уровне, что создаёт значительный потенциал для развития в направлении автоматизированного управления продуктом.

Измерение эффективности продуктовых решений, принятых на основе прогнозов, является отдельной методологической проблемой. Классические методы атрибуции (last-click, first-click, линейная) неприменимы, поскольку решение может влиять на пользователя в долгосрочной перспективе, а не только на момент конверсии. Например, удерживающее сообщение, отправленное сегодня, может предотвратить отток, который произошёл бы через две недели. Простая атрибуция по последнему событию не сможет правильно приписать этот эффект. В этой связи предпочтительным подходом является инкрементальное измерение через рандомизированные контролируемые испытания (RCT): когда решение (например, запуск удерживающей коммуникации) применяется к случайно выбранной группе пользователей, а эффект оценивается как разница в ключевых метриках между этой группой и контрольной группой, не получившей воздействия. Такой подход позволяет отделить эффект именно продуктового решения от влияния внешних факторов и временных трендов. Важно, что модель машинного обучения, используемая для прогноза, не должна оценивать свой собственный эффект – для этого нужен независимый измерительный контур [5]. На практике это означает, что решения, принятые на основе прогнозов, должны рандомизироваться на уровне отдельных пользователей или сегментов, а результаты сравниваться с контрольной

группой, где решения принимались без использования модели (например, по стандартному протоколу). Только так можно получить несмещённую оценку того, насколько модель улучшает реальные бизнес-показатели по сравнению с существующим процессом.

Отдельного внимания заслуживают регуляторные ограничения, связанные с обработкой персональных данных при построении прогнозных моделей. В Российской Федерации действует Федеральный закон № 152-ФЗ «О персональных данных», который требует минимизации собираемых данных, получения согласия на обработку и обеспечения безопасности [6]. Применительно к прогнозным моделям это означает, что использование персональных идентификаторов (email, phone, device ID) должно быть ограничено, предпочтительна псевдонимизация, а сами модели не должны принимать решения, затрагивающие права пользователей, без возможности человеческого контроля. Например, если модель принимает решение о блокировке пользователя или о принудительном изменении тарифа, это должно происходить только с участием человека. В европейской практике аналогичные требования закреплены в GDPR, а также в Акте об искусственном интеллекте (EU AI Act), который классифицирует системы прогнозирования поведения пользователей как высокорисковые при определённых условиях. Это означает, что для таких систем требуется проведение оценки соответствия, ведение журналов событий и обеспечение прозрачности алгоритмов. Таким образом, архитектура любой системы, использующей машинное обучение для управления продуктом, должна с самого начала включать механизмы privacy-by-design: минимизацию данных, короткие сроки хранения, псевдонимизацию в аналитическом слое и полную аудитируемость всех автоматических решений. Без соблюдения этих требований внедрение предиктивной аналитики может привести к юридическим рискам и потере доверия со стороны пользователей. Более того, в некоторых юрисдикциях пользователи имеют право на объяснение решения, принятого алгоритмом, что накладывает дополнительные требования к интерпретируемости моделей.

Практическая реализация описанных подходов требует интеграции нескольких компонентов: системы сбора событий, хранилища данных, вычислительного слоя для обучения и инференса моделей и системы оркестрации действий. В качестве системы сбора событий могут выступать такие инструменты, как Segment, Snowplow или собственные разработки на основе Kafka. Хранилище данных обычно реализуется на базе Snowflake, BigQuery или Redshift. Для обучения моделей часто используются управляемые сервисы вроде AWS SageMaker, Google Vertex AI или Databricks. Оркестрация действий может быть построена на Apache Airflow, Temporal или специализированных решениях для автоматизации маркетинга и продуктовых экспериментов. Однако ключевым фактором успеха является не столько технологический стек, сколько выработка дисциплины: регулярное обновление моделей, валидация гипотез через эксперименты, прозрачная связь между прогнозом, действием и измеренным эффектом. Команды продуктового менеджмента, которые внедряют такую дисциплину, постепенно переходят от реактивного управления к проактивному, когда решения принимаются на основе прогнозов, а не постфактум анализа уже случившихся событий [7]. В долгосрочной перспективе это позволяет не только повысить ключевые метрики, но и сократить когнитивную нагрузку на менеджеров, освобождая их время для стратегического планирования и креативных задач, которые не могут быть автоматизированы. Именно в этом заключается конечная цель применения предиктивной аналитики в

продуктовом менеджменте: не заменить человека, а дать ему инструменты для принятия более качественных и своевременных решений.

При написании статьи были применены технологии искусственного интеллекта.

Список литературы

1. Ремизова, А. А. Поведенческая аналитика: анализ современного состояния и ее применение для решения задач бизнеса / А. А. Ремизова, Т. Р. Самигулин. – Текст: электронный // КиберЛенинка. – URL: https://cyberleninka.ru/article/n/povedencheskaya-analitika-analiz-sovremennogo-sostoyaniya-i-ee-primenenie-dlya-resheniya-zadach-biznesa (дата обращения: 02.04.2026).
2. Марчук, В. В. Оптимизация бизнес-процессов с использованием прогнозной аналитики, современных экономических решений и инноваций / В. В. Марчук, Н. А. Шатохин, Е. В. Сенотрусова, Н. С. Лапшин, В. О. Черненко. – Текст: электронный // КиберЛенинка. – URL: https://cyberleninka.ru/article/n/optimizatsiya-biznes-protsessov-s-ispolzovaniem-prognoznoy-analitiki-sovremennyh-ekonomicheskih-resheniy-i-innovatsiy (дата обращения: 02.04.2026).
3. 7 Advanced Machine Learning Models for Customer Insights. – 2025. – URL: https://madgicx.com/blog/advanced-machine-learning-models-for-customer-insights (дата обращения: 02.04.2026).
4. Top 5 Machine Learning Models for LTV Prediction. – 2025. – URL: https://www.artisangrowthstrategies.com/blog/top-5-machine-learning-models-for-ltv-prediction (дата обращения: 02.04.2026).
5. Влияние предиктивной аналитики на деятельность компаний. – Текст: электронный // КиберЛенинка. – URL: https://cyberleninka.ru/article/n/vliyanie-prediktivnoy-analitiki-na-deyatelnost-kompaniy (дата обращения: 02.04.2026).
6. Федеральный закон от 27.07.2006 № 152-ФЗ «О персональных данных» (последняя редакция). – Текст: электронный // КонсультантПлюс. – URL: https://www.consultant.ru/document/cons_doc_LAW_61801/ (дата обращения: 02.04.2026).
7. Михайлов, Н. Д. Рыночные тенденции интернет-рекламы в России (2024–2025 гг.) / Н. Д. Михайлов. – Текст: электронный // КиберЛенинка. – 2025. – URL: https://cyberleninka.ru/article/n/rynochnye-tendentsii-internet-reklamy-v-rossii-2024-2025-gg (дата обращения: 02.04.2026).

References

1. Remizova, A. A. Behavioral analytics: analysis of the current state and its application to solving business problems / A. A. Remizova, T. R. Samigulin. – Text: electronic // CyberLeninka. – URL: https://cyberleninka.ru/article/n/povedencheskaya-analitika-analiz-sovremennogo-sostoyaniya-i-ee-primenenie-dlya-resheniya-zadach-biznesa (date of access: 02.04.2026).
2. Marchuk, V. V. Optimization of business processes using predictive analytics, modern economic solutions and innovations / V. V. Marchuk, N. A. Shatokhin, E. V. Senotrusova, N. S. Lapshin, V. O. Chernenko. – Text: electronic // CyberLeninka. – URL: https://cyberleninka.ru/article/n/optimizatsiya-biznes-protsessov-s-ispolzovaniem-

prognoznoy-analitiki-sovremennyh-ekonomicheskih-resheniy-i-innovatsiy (date of access: 02.04.2026).
3. 7 Advanced Machine Learning Models for Customer Insights. – 2025. – URL: https://madgicx.com/blog/advanced-machine-learning-models-for-customer-insights (date of access: 02.04.2026).
4. Top 5 Machine Learning Models for LTV Prediction. – 2025. – URL: https://www.artisangrowthstrategies.com/blog/top-5-machine-learning-models-for-ltv-prediction (date of access: 02.04.2026).
5. The Impact of Predictive Analytics on Company Performance. – Text: electronic // CyberLeninka. – URL: https://cyberleninka.ru/article/n/vliyanie-prediktivnoy-analitiki-na-deyatelnost-kompaniy (date of access: 02.04.2026).
6. Federal Law of 27.07.2006 No. 152-FZ "On Personal Data" (latest revision). – Text: electronic // ConsultantPlus. – URL: https://www.consultant.ru/document/cons_doc_LAW_61801/ (access date: 04/02/2026).
7. Mikhailov, N. D. Market trends in online advertising in Russia (2024–2025) / N. D. Mikhailov. – Text: electronic // CyberLeninka. – 2025. – URL: https://cyberleninka.ru/article/n/rynochnye-tendentsii-internet-reklamy-v-rossii-2024-2025-gg (access date: 04/02/2026).