

УДК 004.8.032

***РАЗВИТИЕ МОБИЛЬНЫХ СИСТЕМ РЕКОМЕНДАЦИЙ: ИНТЕГРАЦИЯ  
МАШИННОГО ОБУЧЕНИЯ И АДАПТИВНЫХ АЛГОРИТМОВ***

***Кузнецов И.А.***

*бакалавр,*

*Удмуртский государственный университет,*

*Ижевск, Удмуртия*

***Рубин И.М.***

*магистр,*

*Национальный исследовательский университет ИТМО,*

*Санкт-Петербург, Россия*

**Аннотация**

В статье исследуется влияние машинного обучения (МО) и адаптивных алгоритмов (АА) на эффективность мобильных систем рекомендаций. Авторы подчеркивают роль этих технологий в повышении точности и индивидуализации предложений пользователю. Основываясь на анализе методов коллаборативной и контентной фильтрации, а также гибридных моделей, демонстрируется, как внедрение МО и АА позволяет системам рекомендаций более точно прогнозировать предпочтения пользователей и адаптироваться к их изменениям. Приведены примеры успешного применения этих технологий в практике мобильных приложений, что подтверждается увеличением пользовательской активности и удовлетворенности. Исследование показывает, что интеграция МО и АА в мобильные системы рекомендаций не только улучшает пользовательский опыт, но и способствует росту конверсии и повышает финансовые показатели приложений.

**Ключевые слова:** мобильные системы рекомендаций, машинное обучение, адаптивные алгоритмы, персонализация контента, пользовательский опыт.

***DEVELOPMENT OF MOBILE RECOMMENDATION SYSTEMS:  
INTEGRATION OF MACHINE LEARNING AND ADAPTIVE ALGORITHMS***

***Kuznetsov I.A.***

*bachelor,*

*Udmurt State University,*

*Izhevsk, Udmurtia*

***Rubin I.M.***

*master,*

*University ITMO,*

*St. Petersburg, Russia*

**Abstract**

The article investigates the impact of machine learning (ML) and adaptive algorithms (AA) on the efficiency of mobile recommendation systems. The authors emphasize the role of these technologies in improving the accuracy and personalization of user suggestions. Based on an analysis of collaborative and content filtering methods, as well as hybrid models, it demonstrates how the integration of ML and AA allows recommendation systems to more precisely predict user preferences and adapt to their changes. Examples of successful application of these technologies in mobile app practices are provided, evidenced by an increase in user activity and satisfaction. The research shows that integrating ML and AA into mobile recommendation systems not only enhances the user experience but also contributes to conversion growth and improves financial performance of the applications.

**Keywords:** mobile recommendation systems, machine learning, adaptive algorithms, content personalization, user experience.

**Введение**

Системы рекомендаций предоставляют пользователям приложений релевантный контент и обеспечивает его фильтрацию. Развитие

технологий машинного обучения (МО) значительно повысило точность и персонализацию рекомендаций, за счет чего они стали предоставлять пользователям более точно подобранный контент. В мобильных приложениях (МП), где пользовательский опыт может значительно варьироваться, качественные рекомендации приобретают все более важное значение. С помощью адаптивных алгоритмов (АА) возможно значительно улучшить прогнозирование пользовательских предпочтений. Работа АА опирается на анализ поведения человека, что повышает персонализацию его взаимодействия с МП [1].

Целью данного исследования является анализ влияния МО и АА на мобильные системы рекомендаций. В статье анализируется интеграция данных технологий в МП и их возможности для повышения эффективности и персонализации предложений.

### **Основная часть**

МО играет ключевую роль в разработке и оптимизации рекомендательных систем, способствуя увеличению их точности и уровня персонализации. МО внедряется в системы рекомендаций для обработки и анализа больших объемов данных о пользовательских предпочтениях и их взаимодействиях с продуктами, что позволяет прогнозировать область интересов клиента. Принципы МО в работе рекомендательных алгоритмов:

**Коллаборативная фильтрация (Collaborative filtering, CF).** Метод CF использует оценки и поведение других похожих пользователя для рекомендации продуктов. Метод CF предполагает: если два случайных клиента МП имели раньше схожие предпочтения, то есть вероятность, что их выбор снова совпадет [2]. CF может быть реализован через два основных подхода [3]:

- **User-based CF:** оценивает сходство пользовательских предпочтений и оценок на основе их взаимодействия с различными товарами, используя такие метрики, как косинусное сходство или корреляция Пирсона.

- **Item-based CF:** сосредотачивается на сходстве между товарами, исходя из пользовательских оценок, что часто ведет к более стабильным рекомендациям, поскольку вкусы потребителей могут меняться со временем, в то время как сходство между товарами остается относительно постоянным.

**Контентная фильтрация (Content-based filtering, CBF).** Подход CBF фокусируется на характеристиках самих продуктов и основан на анализе содержания (текстов, описаний, спецификаций) продуктов для выявления их сходств. Метод CBF позволяет выделить нужные признаки из объектов и создает профиль интересов пользователя МП, что позволяет прогнозировать его реакцию на новый контент [4].

**Гибридные модели.** Объединяют CF и CBF с другими методами МО для создания более комплексных рекомендаций. Например:

- внедрение моделей на основе МО [5, 6]: деревья решений (decision trees, алгоритмы МО, которые моделируют решения и их возможные последствия как ветвящуюся структуру с конечным решением); методы случайного леса (random forests, ансамблевые алгоритмы, которые объединяют полученные прогнозы); градиентный бустинг (gradient boosting, МО, где новые модели последовательно строятся для исправления ошибок предыдущих). Такие модели могут обрабатывать большое количество разнородных данных и находить сложные нелинейные зависимости между характеристиками пользователей и их предпочтениями.

- глубокое обучение [7]: нейронные сети, особенно рекуррентные и сверточные, а также сети с механизмами внимания, позволяют выявлять глубокие паттерны в данных, что особенно полезно для обработки естественного языка (Natural Language Processing, NLP) и анализа изображений, часто используемых в контентной фильтрации [3].

АА динамически изменяют свои параметры или структуру в ответ на изменение контекста использования или поведения пользователей [8]. Этот результат достигается через механизмы обратной связи и самообучение. АА

непрерывно собирают данные о взаимодействии подписчиков мобильного сервиса с предложенными рекомендациями, включая просмотренные страницы, время нахождения на них и выбор. Система анализирует собранные данные, используя алгоритмы МО для выявления новых предпочтений или изменений в поведении клиентов платформы. На основе анализа система адаптирует свои рекомендации, корректируя их для соответствия новым данным о пользовательских предпочтениях. Это может включать изменение весов в модели предсказания или выбор других алгоритмов для генерации рекомендаций.

Благодаря применению АА исходная точность рекомендаций может увеличиться с 70% до 85%, что значительно увеличивает конверсию в подписку и повышает удовлетворенность потребителя [9]. Согласно опыту крупных стриминговых сервисов, благодаря более актуальным и персонализированным рекомендациям среднее время использования приложения пользователями может возрасти с 15 до 25 минут в день [5]. Полученные результаты позволяют более эффективно удерживать пользователей приложений [10].

Данные, представленные на рисунке 1, демонстрируют рост вовлеченности пользователей во взаимодействие с МП в результате интеграции АА и МО.




Рис.1. Влияние АА на пользователей МП [1]

Согласно изученным данным, до применения алгоритмов МО в приложение HeartHealth Monitor рекомендации имели точность около 60% [11]. Для повышения персонализации пользовательских рекомендаций разработчики использовали метод градиентного бустинга. Указанный метод позволил

Дневник науки | [www.dnevniknauki.ru](http://www.dnevniknauki.ru) | СМИ ЭЛ № ФС 77-68405 ISSN 2541-8327

увеличить точность прогнозируемых рекомендаций. Его внедрение обеспечило высокую степень индивидуализации рекомендаций, с учетом уникальных данных, связанных со здоровьем пользователя. Изначально среднее время использования приложения пользователями составляло 10 минут в день, а уровень их удовлетворенности достигал 25%. Однако после интеграции технологий МО, точность рекомендаций увеличилась до 64%. Это улучшение привело к росту среднего времени до 20 минут в день, а также повысило уровень удовлетворенности клиентов до 47% [11].

Применение АА в МП Duolingo персонализировало учебный процесс под индивидуальные нужды учеников. Такое решение увеличило количество человек, которые завершили текущий курс обучения, с 50% до 65% [12]. В то же время, приложение Instagram продемонстрировало рост вовлеченности посетителей площадки на 50% после оптимизации алгоритмов подачи контента (лайки, комментарии).

Исследования в области МО и АА в последнее время сосредоточены на создании самообучающихся систем. В 2023 году команда DeepMind провела исследование, направленное на улучшение РС в МП с использованием обучения с подкреплением [7]. Целью проекта была разработка алгоритма, способного максимизировать вовлеченность и удовлетворенность пользователей за счет персонализации предлагаемого контента в новостных МП. Для достижения этих целей DeepMind инвестировала в проект около 5 миллионов долларов. Разработанный алгоритм демонстрировал способность адаптировать контент под индивидуальные пользовательские предпочтения с точностью до 90%. Это привело к увеличению среднего времени использования приложения на 25% и улучшению общего уровня удовлетворенности пользователей на 30%.

Компании часто исследуют методы обработки неструктурированных данных, что включает анализ текстов и изображений с использованием таких методов, как обработка естественного языка и компьютерное зрение (Computer vision). Компания IBM инвестировала более 5 миллионов долларов в свои NLP

проекты с 2022 года, стремясь улучшить понимание пользовательских отзывов и предпочтений [9, 11, 13]. В таблице 1 представлены данные, которые иллюстрируют изменение показателей эффективности МП после внедрения АА.

Таблица 1 – Сравнительный анализ показателей эффективности МП [3]

Приложение	Показатель	До исп-я АА	После исп-я АА	Изменение доходности после оптимизации АА
Spotify	Время использования	1,5 часа	2 часа	Увеличение среднего дохода на 3 доллара с каждого пользователя
Duolingo	Процент выполнения уроков	60%	75%	Рост конверсии в подписку на 5%
Instagram	Уровень взаимодействия	15%	25%	Повышение среднего дохода от рекламы на 0,12 долларов на каждого потребителя контента
Kindle	Время чтения	1 час	1,5 часа	Рост продаж в среднем на 5 долларов на каждого читателя
HeartHealth Monitor	Точность рекомендаций	60%	90%	Рост продаж премиум-доступа на 10%

Анализируя сведения (табл. 1), можно сделать вывод о значительном положительном влиянии АА на производительность и пользовательскую привлекательность МП. Интеграция алгоритмов в работу приложений может существенно оптимизировать системы рекомендаций через улучшение таких аспектов, как точность рекомендаций и удержание внимания клиентов. Кроме того, внедрение АА влияет на увеличение доходности приложений, подтверждая тесную связь между качественным пользовательским опытом и финансовыми результатами компании. Такое решение отражает общую тенденцию повышения ценности и эффективности индивидуального опыта пользователя при взаимодействии с МП.

### **Выводы**

Внедрение алгоритмов и МО в развитие системы рекомендаций может значительно повысить пользовательский интерес к МП. Они способствуют улучшению точности рекомендаций и значительно повышают активность пользователей во взаимодействии с МП. Кроме того, изучение влияния

адаптивных алгоритмов и МО в рекомендательных системах выявляет следующую корреляцию: технологическая автоматизация, которая предполагает стандартизацию процессов, приводит к значительному увеличению персонализации во взаимодействии с клиентом. Такая персонализированная настройка контента способна в долгосрочной перспективе помочь удержать клиентов и увеличить прибыль компании.

### Библиографический список

1. Артемов А.А. МОНИТОРИНГ КАЧЕСТВА ДАННЫХ С ПОМОЩЬЮ AMAZON DEEQU // Вестник науки. – 2024. – №1(70).
2. Давлетов А.Р. СОВРЕМЕННЫЕ МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ И ТЕХНОЛОГИЯ OCR ДЛЯ АВТОМАТИЗАЦИИ ОБРАБОТКИ ДОКУМЕНТОВ // Вестник науки. – 2023. – №10(67).
3. Grepan V. THEORETICAL AND PRACTICAL FOUNDATIONS OF SMART CONTRACT VALIDATION // Innovacionnaya nauka. – 2024. – №3-2/2024. – p. 24-28
4. Петрова, Н. С. Искусственный интеллект как механизм предотвращения оттока клиентов / Н. С. Петрова // Экономика и бизнес: теория и практика. – 2023. – № 11-2(105). – С. 201-204. – DOI 10.24412/2411-0450-2023-11-2-201-204. – EDN OIWSIE.
5. Можаровский Е.А. Интеграция больших языковых моделей (LLM) в мобильные приложения / Е.А. Можаровский // Инновационные подходы в современной науке: сб. ст. по материалам CLIX Международной научно-практической конференции «Инновационные подходы в современной науке». – № 3(159). – М., Изд. «Интернаука», 2024.
6. Можаровский Е.А. ТЕХНОЛОГИИ МАШИННОГО ОБУЧЕНИЯ В МОБИЛЬНОЙ РАЗРАБОТКЕ // Научный сетевой журнал «Столыпинский вестник». – 2024. - №3.
7. Tiumentsev D.V., Shaikhulov E.A. Synthesis of DevOps and ML: optimizing IT workflow // Modern scientific researches and innovations. 2024. № 2 [Electronic journal]. URL: <https://web.snauka.ru/en/issues/2024/02/101567>
8. Bukhtueva I. MACHINE LEARNING APPLICATIONS IN MARKETING: ENHANCING CUSTOMER SEGMENTATION AND TARGETING// Proceedings of the XLI International Multidisciplinary Conference «Prospects and Key Tendencies of Science in Contemporary World». Bubok Publishing S.L., Madrid, Spain. 2024.



9. Ogarkov A. Enhancing commercial effectiveness in pharmaceuticals: a case study on the implementation of successful sales and marketing strategies / A. Ogarkov // Issues of management and economics: current state of current problems: collection. Art. based on materials from the LXXX International Scientific and Practical Conference “Issues of Management and Economics: Current State of Current Problems.” – No. 2(71). – М., Ed. "Internauka", 2024.

10. Огарков А.И. Управление эффективностью продаж и маркетинговой деятельности в фарминдустрии // Научный сетевой журнал «Столыпинский вестник». – 2024. - №3.

11. Захаров А.Д. Эффекты цифровизации финансовых услуг на динамику потребительского кредитования в США // ДНЕВНИК НАУКИ. – 2024. - №1.

12. Mussin Z. Innovations in financial management as a factor in the economic development in the US transportation industry// Proceedings of the LIV International Multidisciplinary Conference «Recent Scientific Investigation». Primedia E-launch LLC. Shawnee, USA. 2024.

13. Козлова М.Д. Построение и оптимизация бизнес-процессов в медицине: сохранение инноваций при фокусе на прибыль / М.Д. Козлова // Инновационные подходы в современной науке: сб. ст. по материалам CLVII Международной научно-практической конференции «Инновационные подходы в современной науке». – № 1(157). – М., Изд. «Интернаука», 2024.

*Оригинальность 88%*