

Пономарев Никита Анатольевич,
экономический факультет, 2 курс, магистратура,
направление бизнес-информатика 38.04.05, КубГУ

ПРОБЛЕМЫ И ОГРАНИЧЕНИЯ СУЩЕСТВУЮЩИХ СИСТЕМ ПЕРСОНАЛИЗАЦИИ

Аннотация. В статье рассматриваются ключевые проблемы и ограничения современных систем персонализации цифрового контента. Анализируются технические, алгоритмические, когнитивные и этические барьеры, снижающие эффективность персонализированного подхода. Особое внимание уделяется проблеме «холодного старта», эффекту «фильтрующего пузыря» и вопросам конфиденциальности данных. Предложены направления совершенствования архитектур персонализации.

Ключевые слова: Персонализация, рекомендательные системы, фильтрующий пузырь, холодный старт, конфиденциальность данных, коллаборативная фильтрация.

Введение

Современные цифровые платформы – от маркетплейсов и стриминговых сервисов до социальных сетей и новостных агрегаторов – в значительной степени полагаются на алгоритмы персонализации. Персонализация контента стала не просто конкурентным преимуществом, но и необходимым условием удержания аудитории в условиях информационной перегрузки. Согласно данным аналитических агентств, внедрение систем персонализации позволяет повысить вовлеченность пользователей на 30-50% [1]. Однако практическое применение таких систем выявило комплекс проблем, которые существенно ограничивают их точность, масштабируемость и этичность.

Задача данной работы – систематизировать и подробно описать основные ограничения существующих систем персонализации, а также предложить возможные пути их преодоления на основе анализа современной научной литературы. В статье последовательно рассматриваются технико-алгоритмические ограничения, когнитивные и социальные ограничения, а также этические и правовые проблемы персонализации.

1. Технические и алгоритмические ограничения

1.1. Проблема «холодного старта»

Одним из наиболее фундаментальных и широко обсуждаемых ограничений является проблема «холодного старта» (cold start problem). Она возникает в ситуациях, когда система персонализации не имеет достаточного объема данных о новом пользователе или о новом объекте (товаре, статье, видео). В таких условиях формирование качественных рекомендаций становится невозможным или крайне затруднительным.

Различают несколько типов «холодного старта»: «холодный старт» нового пользователя (человек не оставил поведенческих следов), «холодный старт» нового объекта (товар не имеет истории взаимодействий) и «холодный старт» системы в целом (запуск новой платформы). В методах коллаборативной фильтрации, основанных на анализе сходства между пользователями, эта проблема проявляется наиболее остро. Эмпирические исследования показывают, что точность рекомендаций для новых пользователей падает на 40-60% в первые часы использования системы по сравнению с активными пользователями [2, с.2067]. Для смягчения проблемы используются гибридные подходы, однако они не устраняют ее полностью.

1.2. Высокая разреженность данных

Следующее значимое ограничение связано с высокой разреженностью матриц взаимодействий «пользователь – объект». В реальных системах персонализации количество потенциальных взаимодействий колоссально, однако реально зафиксированных



взаимодействий крайне мало. Типичная разреженность составляет 95-99%, а в некоторых доменах достигает 99,9% [3].

Разреженность данных вызывает серьезные проблемы. Во-первых, алгоритмы становятся неустойчивыми: небольшие изменения в выборке могут приводить к кардинальному изменению рекомендаций. Во-вторых, повышается риск переобучения (overfitting), когда модель запоминает шумовые паттерны. В-третьих, статистически значимые корреляции удается извлечь только для наиболее активных сегментов аудитории.

1.3. Вычислительная сложность в реальном времени

Современные системы персонализации все чаще переходят к формированию рекомендаций в реальном времени. Допустимая задержка ответа для большинства веб-приложений составляет 100-200 мс. Однако современные гибридные модели на основе глубоких нейронных сетей предъявляют высокие требования к вычислительным ресурсам. Прямой вызов тяжелой модели может приводить к задержкам в 300-500 мс и более [4].

Возникает дилемма: либо уменьшение модели (с потерей точности), либо увеличение задержки ответа, что ухудшает пользовательский опыт. На высоконагруженных платформах эта проблема усугубляется необходимостью горизонтального масштабирования.

2. Когнитивные и социальные ограничения

2.1. Эффект «фильтрующего пузыря»

Наряду с техническими ограничениями существуют когнитивные и социальные барьеры. Ключевым из них является эффект «фильтрующего пузыря» (filter bubble) – понятие, введенное Эли Парайзером в 2011 году [5].

Системы персонализации, оптимизируя метрики вовлеченности, начинают все более узко подбирать контент под исторические паттерны поведения пользователя. Пользователь постепенно оказывается в информационном «пузыре», где видит преимущественно ту информацию, которая подтверждает его существующие взгляды и вкусы. Эмпирические исследования показывают, что уже после 30-40 взаимодействий разнообразие предлагаемого контента падает более чем на 70% [6, с.154].

Особенно опасен этот эффект в новостных и социальных медиа, где он способствует поляризации общества, укреплению радикальных взглядов и снижению способности воспринимать альтернативные точки зрения.

2.2. Снижение серендипности

Прямым следствием фильтрующего пузыря становится снижение серендипности – способности системы предлагать неожиданные, но полезные и интересные объекты. Серендипность принципиально отличается от простой точности: рекомендация может быть точной, но не приносить новой ценности.

Большинство традиционных метрик (precision, recall) ориентированы исключительно на предсказуемость. Акцент на этих метриках приводит к «замыливанию» рекомендаций – многократному повторению однотипного контента. Например, если пользователь купил кухонный нож, система начнет рекомендовать ему другие ножи, а не разделочную доску или книгу рецептов [3].

3. Этические и правовые ограничения

3.1. Непрозрачность алгоритмов («черные ящики»)

Отдельную группу проблем составляют этические и правовые ограничения. Большинство коммерческих систем используют многослойные нейронные сети, которые не предоставляют человеку читаемого объяснения того, почему конкретному пользователю был предложен тот или иной объект.

Проблема «черного ящика» создает три серьезных последствия. Во-первых, пользователи теряют доверие к системе. Во-вторых, разработчикам трудно диагностировать



ошибки. В-третьих, это создает юридические риски. Статья 22 Общего регламента защиты данных (GDPR) Европейского союза предоставляет пользователям право на объяснение принятого алгоритмического решения [7]. Аналогичные требования содержатся в проекте Закона об искусственном интеллекте ЕС (EU AI Act).

3.2. Дискриминационные эффекты

Системы персонализации могут не только отражать, но и усиливать существующие социальные неравенства. Как показано в исследовании [8, с.208], пользователи с низкой цифровой грамотностью получают упрощенные, повторяющиеся рекомендации, ведущие к информационной деградации.

Кроме того, модели способны дискриминировать пользователей по косвенным признакам, воспроизводя исторические предубеждения. Классический пример – рекомендательная система Amazon по найму, которая дискриминировала женщин-кандидатов [3].

3.3. Проблема приватности

Системы персонализации требуют сбора больших объемов данных о пользователях. Это вступает в противоречие с принципами минимизации данных (data minimization) и проектирования с защитой приватности (privacy by design). Только за 2024 год зафиксировано несколько крупных утечек из систем персонализации, в результате которых скомпрометировано свыше 2,7 млрд записей пользователей.

4. Направления преодоления ограничений

Анализ литературы позволяет выделить несколько перспективных направлений. В области борьбы с «холодным стартом» наиболее эффективны гибридные архитектуры, сочетающие коллаборативную фильтрацию с контентным анализом, а также байесовские методы [2].

Для обеспечения работы в реальном времени развиваются методы дистилляции знаний, аппаратного ускорения и двухконтурные архитектуры (грубая фильтрация на легких моделях, точное ранжирование на тяжелых) [4].

Противодействие эффекту «фильтрующего пузыря» требует введения метрик разнообразия и серендипности в функцию потерь. Также применяются методы баланса между эксплуатацией известных предпочтений и исследованием нового – например, многорукие бандиты (multi-armed bandits) [6].

Вопросы приватности могут быть решены с помощью федеративного обучения (federated learning) и дифференциальной приватности [7]. Для обеспечения объяснимости разрабатываются методы постфактумного объяснения (LIME, SHAP) и создаются собственно объяснимые архитектуры.

Заключение

Существующие системы персонализации сталкиваются с комплексом взаимосвязанных ограничений: технических (разреженность данных, «холодный старт», вычислительная сложность), когнитивных (фильтрующие пузыри, снижение серендипности) и этических (непрозрачность, дискриминация, риски приватности). Преодоление этих ограничений требует пересмотра целевых метрик и архитектурных принципов. Необходимо смещение фокуса с краткосрочной вовлеченности на долгосрочную пользу для пользователя и общества: разнообразие контента, объяснимость рекомендаций, справедливость, защита приватности. Без таких изменений персонализация рискует приносить сиюминутный рост вовлеченности в ущерб долгосрочному доверию пользователей.

Список литературы:

1. Ricci F., Rokach L., Shapira B. Recommender Systems: Handbook. 3rd ed. New York: Springer. 2022. 1050 p.



2. Lika B., Kolomvatsos K., Hadjiefthymiades S. Facing the cold start problem in recommender systems // *Expert Systems with Applications*. 2014. Vol. 41. No. 4. P. 2065–2073.
3. Zhang S., Yao L., Sun A., Tay Y. Deep learning based recommender system: A survey and new perspectives // *ACM Computing Surveys*. 2019. Vol. 52. No. 1. P. 1–38.
4. Covington P., Adams J., Sargin E. Deep neural networks for YouTube recommendations // *Proceedings of the 10th ACM Conference on Recommender Systems*. Boston. 2016. P. 191–198.
5. Pariser E. *The Filter Bubble: What the Internet Is Hiding from You*. New York: Penguin Press. 2011. 304 p.
6. Nguyen T.T., Hui P.M., Harper F.M. Exploring the filter bubble effect in recommender systems // *Proceedings of the 28th ACM Conference on User Modeling, Adaptation and Personalization*. Genoa. 2020. P. 150–158.
7. European Parliament. General Data Protection Regulation (GDPR): Regulation (EU) 2016/679. *Official Journal of the European Union*. 2016. L 119. P. 1–88.
8. Cowgill B., Dell'Acqua F., Deng S. The causes and consequences of algorithmic bias in recommendation systems // *Management Science*. 2023. Vol. 69. No. 4. P. 2055–2075.

