

Контент-ориентированный подход в системах рекомендаций: принципы, методы и метрики эффективности

Н.А. Клёмин, А.А. Аббакумов, А.И. Егунова, А.В. Прончатов,

Д.О. Грошев

Мордовский государственный университет им. Н.П.Огарёва

Аннотация: Данная статья исследует подход контент-ориентированной фильтрации в современных рекомендательных системах, уделяя особое внимание его ключевым принципам, методам реализации и метрикам оценки. В исследовании подчеркиваются преимущества контент-ориентированных систем в сценариях, требующих глубокого анализа объектов и моделирования пользовательских предпочтений, особенно в условиях недостатка данных для коллаборативной фильтрации.

Ключевые слова: контент - ориентированная фильтрация, рекомендательные системы, выделение характеристик, метрики сходства, персонализация.

Введение

В наше время системы рекомендаций оказывают значительное влияние, оптимизируя взаимодействие пользователей с сервисами в самых разных сферах — от цифровой коммерции до платформ с новостями и соцсетей. Их ключевая задача — изучать поведенческие паттерны аудитории и предлагать наиболее релевантные материалы.

Выделяют два базовых способа формирования подобных алгоритмов: контент-ориентированная и коллаборативная фильтрация. В данной статье мы детально рассмотрим специфику первого метода, его достоинства и ограничения, а также проведём параллели с другими вариантами реализации.

Контент-ориентированный подход

Принцип работы контентного метода основан на сравнении пользователей с материалами или продуктами, которые они ранее оценивали позитивно либо приобретали [1]. Ключевой акцент делается на изучении характеристик как самих пользователей, так и объектов рекомендаций [2,3]. К примеру, при подборе музыкальных треков анализируются такие

параметры, как стиль, исполнитель, темп, гармония, аранжировка, тональность, а также эмоциональная окраска произведения.

Для генерации рекомендаций применяются алгоритмы обработки естественного языка (Natural Language Processing – NLP), среди которых обратная частность документа (Term Frequency – Inverse Document Frequency TF-IDF), анализ эмоциональной окраски текстов, а также технологии машинного обучения. [4,5] Основная цель таких методов — составить детализированные «профили» пользователей и рекомендуемых объектов, используя их характеристики.

Рассмотрим пример рекомендации фильмов пользователям. Допустим, в распоряжении имеется каталог из тысячи фильмов, а также набор атрибутов размерностью N . На первом этапе анализируются параметры каждого фильма: жанровая принадлежность, режиссёр, актёрский состав, хронометраж, ключевые слова из описания, а также оценка отзывов на эмоциональный окрас. Далее создаются два вектора:

1. **Вектор фильма** — массив длины N , содержащий единицы для характеристик, присущих данному фильму, и нули для остальных.
2. **Вектор пользователя** — аналогичный массив, где хранятся вероятностные оценки предпочтений зрителя на основании просмотренных и оценённых ранее фильмов.

На основе этих данных вычисляется схожесть между пользователем и фильмами. Подбор рекомендаций осуществляется, если:

1. Кино соответствует интересам зрителя с высокой степенью точности.
2. Фильм схож с теми, что пользователь уже просматривал и оценивал положительно.

Для оценки схожести между объектами используются следующие метрики:

1) Косинусное сходство

Этот метод позволяет определять степень схожести объектов по их характеристикам. В области рекомендаций он используется для расчёта близости между вектором предпочтений пользователя и векторами возможных рекомендаций.

Метод особенно эффективен при анализе многомерных данных, таких как тексты или сложные контентные структуры. Косинусное сходство измеряется через угол между двумя векторами: чем ближе значение к 1, тем сильнее совпадение. [6]

2) Коэффициент Жаккара

Также известный как мера пересечения над объединением, этот показатель измеряет схожесть, сравнивая число общих и уникальных характеристик. Его удобно использовать при бинарных представлениях данных, когда атрибуты либо присутствуют (1), либо отсутствуют (0).

Метод подходит в ситуациях, когда нужно учитывать только наличие или отсутствие характеристик, но не их вес или рейтинг. Однако его эффективность снижается, если данные включают числовые оценки или сложные многомерные признаки. [7]

Помимо традиционных контентных подходов, задачу персонализации можно рассматривать как проблему предсказательного анализа. В этом случае применяются классические алгоритмы машинного обучения, такие как случайный лес, градиентный бустинг (например, XGBoost), а также нейросетевые модели.

Такой метод полезен, если на выбор пользователя влияют дополнительные факторы, выходящие за пределы контентных характеристик. Например, при подборе ресторанов можно учитывать не только тип кухни и рейтинг, но и внешние обстоятельства — время суток, погодные условия, геопозицию, а также историю посещений заведений.

Предположим, система должна предсказать, какое блюдо закажет пользователь в сервисе доставки еды. В дополнение к данным о самом блюде (список ингредиентов, калорийность, цена) можно анализировать день недели, температуру воздуха и среднее время ожидания заказа. В совокупности эти признаки помогают модели делать более точные прогнозы.

Такой подход относится к задачам с учителем (supervised learning), где алгоритм обучается на исторических данных и прогнозирует целевые значения — например, вероятность заказа конкретного блюда (0/1), вероятность высокой оценки или ожидаемое число заказов из определённого заведения за месяц.

Таблица №1

Преимущества и недостатки контент-ориентированных методов

Преимущества	Недостатки
1	2
Независимость от данных других пользователей — рекомендации формируются на основе характеристик самого контента, а не действий других пользователей.	Когда появляется новый пользователь с недостатком данных о его транзакциях, мы не можем качественно сделать рекомендации
Интерпретируемость результатов — можно объяснить, почему был предложен тот или иной контент (например, из-за общих жанров или характеристик).	Ограниченность данных о продуктах — если доступно мало информации о товарах, различать их и формировать качественные рекомендации становится сложно.

1	2
Отсутствие проблемы "холодного старта" для новых предметов – поскольку рекомендации строятся на признаках самих объектов, новые продукты могут быть сразу включены в систему.	Эффект "туннелирования" – система может постоянно рекомендовать пользователю однообразный контент, ограничивая разнообразие и снижая ценность рекомендаций.
Гибкость в использовании признаков – можно учитывать не только основные характеристики (жанр, автор, ключевые слова), но и дополнительные (эмоциональный тон, стиль, сложность).	Высокая зависимость от качества признаков – если описание товаров содержит мало полезной информации или оно плохо структурировано, рекомендации могут быть нерелевантными.

Альтернативный метод: коллаборативная фильтрация

Этот метод опирается на идею, что люди с схожими вкусами, вероятнее всего, заинтересуются похожими продуктами или медиаконтентом. Если два человека (X и Y) в прошлом выбирали одни и те же позиции, то можно ожидать, что X заинтересуется тем, что недавно приобрёл Y, даже если раньше не сталкивался с этим вариантом.[8]

В отличие от контент-ориентированного подхода, совместная фильтрация не анализирует явные характеристики товаров или пользователей. В её основе — операции с матрицей взаимодействий (матрицей полезности), фиксирующей пользовательские действия: покупки, клики, отметки «нравится» и другие сигналы. [9]

Кластеризация в рекомендациях

Когда данных с разметкой нет, а нужно обнаружить скрытые группы пользователей или товаров, применяется кластеризация. Например, если сервис только запущен и истории взаимодействий немного, можно группировать людей по схожести их активности (например, по музыкальным предпочтениям или киножанрам). После этого пользователям предлагается контент, который популярен внутри их сегмента. [12]

Хотя этот подход не даёт идеальных результатов на старте, он создаёт фундамент для дальнейшего улучшения системы. Помимо этого, кластеризация может применяться для конструирования дополнительных признаков. Например, каждому пользователю или товару можно присвоить идентификатор кластера и затем учитывать его при обучении основной модели.

Метрики оценки рекомендаций

Одной из основных сложностей при создании алгоритмов персонализации является выбор показателей, которые помогут улучшить их эффективность. Цель системы — не просто показывать пользователям то, что они уже выбирали, а предлагать им что-то новое, но при этом релевантное. Как же тогда определить, насколько хорошо она работает?

Статистические метрики

Эти метрики помогают измерить разницу между прогнозируемыми оценками и реальными реакциями пользователей.

- **Средняя абсолютная ошибка (MAE – Mean Absolute Error)** и **среднеквадратическая ошибка (RMSE – Root Mean Square Error)** широко применяются для оценки точности предсказанных рейтингов. Чем ниже их значения, тем точнее система определяет вкусы пользователей.

- **Коэффициент Корреляция** показывает, насколько предложенные системой варианты совпадают с фактическими предпочтениями аудитории.

Такие метрики особенно полезны, если алгоритм предсказывает рейтинги или частоту взаимодействий с товарами. [13]

Оптимизация метрик и пользовательский опыт

Важно учитывать, что оптимизация по одной метрике может исказить работу системы. Если, например, алгоритм рекомендует человеку статью, вероятность прочтения которой и так высока, его ценность для бизнеса снижается — ведь пользователь, вероятно, и так бы её выбрал.

Эффективный рекомендательный механизм должен:

- Находить баланс между точностью (precision) и полнотой (recall), чтобы не только повторять известные предпочтения, но и изучать новые.
- Избегать чрезмерного повторения одних и тех же рекомендаций, чтобы сохранять долгосрочное вовлечение.
- Обеспечивать разнообразие предложений, позволяя пользователям открывать что-то новое, а не только то, с чем они уже знакомы.

В конечном итоге, успешная рекомендательная система — это не только точные алгоритмы, но и механизм, который повышает вовлечённость пользователей и делает их взаимодействие с платформой более ценным.

Заключение

Методы, ориентированные на анализ контента, дают возможность формировать индивидуальные предложения, учитывая свойства объектов и вкусы аудитории. Однако у них есть недостатки, связанные с проблемой «первого взаимодействия» и риском однообразных рекомендаций. Совместная фильтрация и алгоритмы машинного интеллекта могут расширять эти подходы, обеспечивая более точный подбор вариантов. В современных системах часто применяется комбинированная стратегия, объединяющая сильные стороны разных методик для достижения оптимальных результатов.

Литература

1. Куралева Е.А., Соколов А.В. Рекомендательные системы в электронной коммерции: методы и алгоритмы // Информационные технологии. 2022. № 5. С. 45-52.
2. Ricci F., Rokach L., Shapira B. Recommender Systems: The Textbook. — Springer, 2022. 456 p.
3. Барсегян А.А., Куприянов М.С., Степаненко В.В. Методы и модели анализа данных: OLAP и Data Mining. СПб.: БХВ-Петербург, 2020. 336 с.
4. Zhang S., Yao L., Sun A., Tay Y. Deep Learning Based Recommender System: A Survey and New Perspectives // ACM Computing Surveys. 2023. Vol. 55, No. 1. P. 1-38.
5. Иванов Д.А., Петров К.Л. Применение машинного обучения в рекомендательных сервисах // Искусственный интеллект и принятие решений. 2023. № 1. С. 78-89.
6. Мельников А.П., Шевченко В.А. Сравнительный анализ методов коллаборативной и контентной фильтрации // Информационные технологии и вычислительные системы. 2023. № 1. С. 67-78

7. Белов П.Н., Гришин К.А. Метрики оценки качества рекомендательных систем // Автоматизация и современные технологии. 2021. № 5. С. 22-29.
8. Тихомиров В.Ю., Лебедев И.С. Гибридные рекомендательные системы: комбинирование контентных и коллаборативных методов // Искусственный интеллект в технических системах. 2022. № 3. С. 55-64.
9. Бусарев, М.И., Кирпичников А.П., Флакс Д.Б. Одноканальная система массового обслуживания с ограниченным средним временем пребывания заявки в системе в целом // Вестник Казанского технологического университета. 2011. № 22. С. 155-161.
10. Афонин В.В., Никулин В.В. Оптимизация марковских систем массового обслуживания с отказами в системе MATLAB // Вестник Астраханского государственного технического университета. Серия: управления, вычислительная техника и информатика. 2018. №. 1. С. 112-120.
11. Шабанов А.П. Подход к оценке производительных ресурсов информационных систем // Бизнес-информатика. 2009. № 2(8). С. 58-63.
12. Кузнецов А.А., Петров В.М. Применение нейросетевых алгоритмов для персонализации рекомендаций в электронной коммерции // Инженерный вестник Дона. 2020. № 3. URL: ivdon.ru/magazine/archive/n3y2020/582
13. Венцов Н.Н., Долгов В.В., Подколизина Л.А. Обзор алгоритмов кластеризации, используемых в задачах поиска изображений по содержанию // Инженерный вестник Дона. 2022. № 2 URL: ivdon.ru/ru/magazine/archive/n3y2016/3707

References

1. Kuraleva E.A., Sokolov A.V. Informacionnye tehnologii. 2022. № 5. pp. 45-52.
 2. Ricci F., Rokach L. Recommender Systems: The Textbook Springer, 2022. 456 p.
-



3. Barsegian A.A., Kuprijanov M.S., Stepanenko V.V. Metody i modeli analiza dannyh [Methods and models of data analysis]: OLAP i Data Mining. SPb.: BHV-Peterburg, 2020. 336 p.
4. Zhang S., Yao L., Sun A., Tay Y. ACM Computing Surveys. 2023. Vol. 55, No. 1. pp. 1-8.
5. Ivanov D.A., Petrov K.L. Iskusstvennyj intellekt i prinjatие reshenij. 2023. № 1. pp. 78-89.
6. Mel'nikov A.P., Shevchenko V.A. Informacionnye tehnologii i vychislitel'nye sistemy. 2023. № 1. pp. 67-78.
7. Belov P.N., Grishin K.A. Avtomatizacija i sovremennye tehnologii. 2021. № 5. pp. 22-29.
8. Tihomirov V.Ju., Lebedev I.S. Iskusstvennyj intellekt v tehniceskikh sistemah. 2022. № 3. pp. 55-64.
9. Busarev, M.I., Kirpichnikov A.P., Flaks D.B. Vestnik Kazanskogo tehnologicheskogo universiteta. 2011. № 22. pp. 155-161.
10. Afonin V.V., Nikulin V.V. Vestnik Astrahanskogo gosudarstvennogo tehniceskogo universiteta. Serija: upravlenija, vychislitel'naja tehnika i informatika. 2018. №. 1. pp. 112-120.
11. Shabanov A.P. Biznes-informatika. 2009. № 2(8). pp. 58-63.
12. Kuznecov A.A., Petrov V.M. Inzenernyj vestnik Dona, 2020. № 3. URL: ivdon.ru/magazine/archive/n3y2020/582/.
13. Vencov N.N., Dolgov V.V., Podkolizina L.A. Inzhenernyj vestnik Dona, 2022, № 2. URL: ivdon.ru/ru/magazine/archive/n3y2016/3707/.

Дата поступления: 8.03.2025

Дата публикации: 25.04.2025