

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

**«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИМЕНИ Н. Г. ЧЕРНЫШЕВСКОГО»**

Кафедра дискретной математики и информационных технологий

**РАЗРАБОТКА СИСТЕМЫ РЕКОМЕНДАЦИЙ С
ИСПОЛЬЗОВАНИЕМ АНСАМБЛЕВЫХ МОДЕЛЕЙ И
УЧЁТОМ РАЗНООБРАЗИЯ КОНТЕНТА
АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ**

студента 2 курса 271 группы
направления 09.04.01 — Информатика и вычислительная техника
факультета КНиИТ
Головки Екатерины Сергеевны

Научный руководитель

профессор, к. ф.-м. н., д. э. н

Л. В. Кальянов

Заведующий кафедрой

доцент, к. ф.-м. н.

Л. Б. Тяпаев

Саратов 2024

ВВЕДЕНИЕ

В мире, насыщенном информацией, каждый из нас вынужден найти свой путь сквозь бесконечный поток данных, новостей и мнений. Однако, с ростом количества информации возникает и риск её искажения или ограничения. В современном обществе мы часто сталкиваемся с ситуацией, когда наше восприятие мира ограничено определенными источниками или точками зрения, создавая, таким образом, некий "пузырь" информации вокруг себя.

Именно этот феномен привлекает внимание исследователей и общественных деятелей, поскольку он влияет на наше понимание мира, нашу способность к диалогу и наше восприятие других людей. Разрыв информационного пузыря может привести к изоляции, конфликтам и даже кризисам доверия в обществе.

Цель настоящего исследования заключается в разработке и анализе метода разрыва информационного пузыря в рекомендательной системе для улучшения качества рекомендаций и расширения жанрового разнообразия контента.

Для достижения цели необходимо выполнить следующие задачи:

- познакомиться с понятием и типами рекомендательных систем;
- познакомиться с понятием информационного пузыря;
- познакомиться с параметрами моделей;
- разработать рекомендательную систему с помощью ансамблевого метода LightGBM и диверсификации рекомендаций;
- разработать WEB-приложение для анализа полученных данных;
- сформулировать выводы, опираясь на полученные результаты.

Актуальность темы дипломной работы по анализу информационных пузырей с использованием ансамблевых моделей определяется несколькими ключевыми факторами. В современном мире объем информации постоянно растет, усложняя её обработку и увеличивая риск попадания пользователей в информационные пузыри. В таких условиях люди получают информацию, которая соответствует их текущим убеждениям и интересам, что ограничивает их взгляд на мир и препятствует получению объективной и разнообразной информации. Информационные пузыри значительно влияют на формирование общественного мнения, политические предпочтения и принятие решений в различных сферах жизни. Понимание механизмов их формирования и раз-

рыва может помочь смягчить негативные последствия и способствовать более информированному и критическому мышлению.

Технологический прогресс в области анализа данных, в частности развитие методов машинного обучения и искусственного интеллекта, открывает новые возможности для анализа и выявления информационных пузырей. Ансамблевые модели, такие как бэггинг, бустинг и стекинг, демонстрируют высокую точность и устойчивость при обработке больших и сложных данных, что делает их перспективным инструментом для исследования информационных пузырей. Разработка программного обеспечения для анализа информационных пузырей имеет широкие практические приложения, полезные для социальных сетей, новостных платформ и других онлайн-сервисов. Это может улучшить рекомендационные системы, повысить качество контента и уменьшить поляризацию аудитории. Несмотря на значительный прогресс в изучении информационных пузырей, остается множество нерешенных вопросов, касающихся их формирования, динамики и способов разрыва.

КРАТКОЕ СОДЕРЖАНИЕ РАБОТЫ

Первый раздел "Рекомендательные системы и информационные пузыри" посвящен основным понятиям связанным с рекомендательными системами и информационными пузырями. Так же, рассматриваются причины возникновения информационных пузырей, методы борьбы с информационными пузырями и различия между разнообразием и рекомендацией.

Рекомендательные системы (RS) – это программные инструменты и алгоритмы, предназначенные для предсказания и предложения пользователю контента, товаров или услуг, которые могут быть ему интересны, на основе его предпочтений и поведения. Они являются неотъемлемой частью современного мира информационных технологий и играют важную роль в областях электронной коммерции, социальных сетей, потокового видео, музыки, новостей и многих других.

Рекомендательные системы классифицируются по различным критериям, среди которых метод, используемый системой для выявления и предсказания предпочтений пользователя, является основным. Основные методы включают:

- коллаборативная фильтрация;
- рекомендации на основе контента;
- гибридные рекомендательные системы.

Коллаборативная фильтрация основана на предположении, что пользователи с похожими интересами будут интересоваться похожим контентом в будущем. Существуют два типа коллаборативной фильтрации: пользователь-пользователь (user-user) и элемент-элемент (item-item). Рекомендации на основе контента анализируют характеристики контента для создания рекомендаций, например, предлагая фильмы определенного жанра. Гибридные рекомендательные системы объединяют оба метода для повышения качества рекомендаций.

Для построения рекомендательных систем часто используются алгоритмы машинного обучения и статистические методы, такие как классификация, кластеризация, факторизация матриц и глубокое обучение. Эти методы позволяют анализировать большие объемы данных и выявлять скрытые паттерны в поведении пользователей и характеристиках контента. Ключевой вызов при разработке рекомендательных систем – обеспечение точности и

релевантности рекомендаций, что требует использования различных метрик оценки качества рекомендаций.

Информационный пузырь или параметр фильтров – это концепция, описывающая явление, при котором пользователи ограничивают свой доступ к информации, ограничиваясь исключительно контентом, который соответствует их собственным убеждениям и предпочтениям. Этот термин часто используется в контексте интернета и социальных сетей, где алгоритмы фильтрации контента и персонализации могут создавать "пузыри внутри которых пользователи подвержены узкому спектру информации, исключая контент, который может вызвать диссонанс или несогласие с их установками.

Информационные пузыри формируются в онлайн-среде благодаря алгоритмам персонализации контента, которые анализируют предпочтения и поведение пользователя, предлагая ему наиболее релевантный контент. Это создает фильтрованный поток информации, отражающий предыдущие действия и интересы пользователя, исключая контент, который не соответствует этим предпочтениям. Механизм обратной связи также способствует формированию пузырей: положительная реакция на определенный тип контента приводит к увеличению его предложения в будущем.

Эффекты информационных пузырей включают усиление предвзятости и убеждений пользователей, ограниченное понимание проблем и событий, снижение способности критического мышления и поляризацию общественного мнения. Это может затруднить принятие обоснованных решений и способствовать распространению дезинформации, что представляет угрозу для социальной стабильности и согласия.

Методы разрыва информационного пузыря включают различные стратегии, направленные на преодоление ограничений и увеличение разнообразия информации, доступной пользователю. Введение случайного шума в алгоритмы рекомендаций позволяет увеличить разнообразие контента, предлагаемого пользователю, и снизить вероятность формирования узкой группы рекомендаций. Учет новизны и разнообразия в алгоритмах рекомендаций также способствует предложению пользователю более широкого спектра контента.

Разрыв информационного пузыря – это критически важная задача в эпоху цифровых технологий, когда алгоритмы часто предоставляют пользователям информацию, соответствующую их предыдущим интересам и пред-

почтениям, что ограничивает кругозор и может усилить предвзятость. Ранжированные списки полезны в ситуациях, требующих поиска конкретной информации, так как помогают быстро найти самые релевантные ответы. Важно учитывать разнообразие источников, чтобы получить широкий обзор темы и избежать однобокого восприятия.

Разнообразные списки, напротив, полезны для получения информации из множества различных источников. Это способствует креативности и генерации новых идей, помогает выйти за рамки ограниченного восприятия и лучше понимать глобальные тренды и вызовы. В современном мире, где многие проблемы требуют глобального подхода, важно учитывать культурные, социальные и экономические контексты разных регионов, что помогает избежать однобокого восприятия и способствует объективному анализу информации.

Таким образом, использование методов разрыва информационных пузырей и обеспечение разнообразия информации способствует более глубокому и всестороннему пониманию мира, что особенно важно в условиях цифровизации и глобализации.

Второй раздел "Ансамблевые модели в рекомендательных системах" раскрывает понятие ансамблевых моделей, рассматриваются типы ансамблевых моделей и от чего зависит эффективность ансамблевых моделей. Так же рассматриваются метрики для оценки качества ансамблевых моделей.

Ансамблевые модели в машинном обучении объединяют несколько базовых моделей для повышения точности прогнозов. Этот подход устраняет ошибки отдельных моделей, улучшая общую производительность. Ансамблевые модели применяются в различных областях, таких как компьютерное зрение, обработка языка и финансовое прогнозирование.

Существует три основных типа ансамблевых методов:

- Бэггинг (Bagging Ensemble Learning);
- Стекинг (Stacking Ensemble Learning);
- Бустинг (Boosting Ensemble Learning).

Бэггинг улучшает стабильность и обобщающую способность модели путем обучения нескольких моделей на разных подмножествах данных, полученных с использованием бутстрэп-выборки. Предсказания базовых моделей усредняются или используются для голосования, чтобы получить оконча-

тельный прогноз.

Стекинг включает обучение нескольких разнородных базовых моделей, предсказания которых затем используются для обучения мета-модели. Мета-модель формирует окончательный прогноз, компенсируя слабости отдельных моделей.

Бустинг строит последовательность слабых моделей, где каждая следующая модель исправляет ошибки предыдущей. Веса объектов обновляются на каждом шаге, уделяя больше внимания ошибочным предсказаниям. Конечный прогноз получается путем комбинирования предсказаний всех моделей.

Эффективность ансамблевых моделей зависит от:

- разнообразия моделей;
- качества базовых моделей;
- независимости моделей;
- методов комбинирования предсказаний;
- контроля переобучения;
- количество моделей;
- подбор параметров.

Для оценки качества ансамблевых моделей используются такие метрики, как:

- Среднеквадратичная ошибка (MSE) - оценивает среднеквадратичное отклонение между предсказанными и фактическими значениями;
- Средняя абсолютная ошибка (MAE) - измеряет среднее абсолютное отклонение между предсказанными и фактическими значениями;
- Precision - доля релевантных элементов среди всех предсказанных;
- Recall - доля успешно предсказанных релевантных элементов среди всех релевантных элементов в данных;
- NDCG - оценивает качество ранжирования предсказанных элементов с учетом позиции релевантных элементов;
- Средний предсказанный рейтинг - измеряет среднее значение оценок, предсказанных системой для всех пользователей.

В третьей главе "Разработка математической модели диверсификации рекомендаций" рассматривается выбранный ансамблевый метод, а так же алгоритм разрыва информационного пузыря.

LightGBM (Light Gradient Boosting Machine) — это быстрый и масштабируемый алгоритм градиентного бустинга, который обрабатывает большие объемы данных. Он широко используется для прогнозирования и классификации.

Основные шаги работы с LightGBM:

- Начальное предсказание вычисляется как среднее значение целевой переменной в обучающей выборке.
- Для каждого дерева в ансамбле рассчитываются остатки — разница между реальными значениями и предсказанными на предыдущем шаге.
- Каждое новое дерево обучается на остатках, оптимизируя функцию потерь и добавляя регуляризацию.
- Новые предсказания получаются добавлением взвешенного вклада текущего дерева к предыдущим предсказаниям.

Для устранения информационного пузыря применялся метод диверсификации рекомендаций. Этот метод расширяет предложенные пользователю фильмы, учитывая жанровое разнообразие.

Алгоритм диверсификации рекомендаций включает следующие шаги:

- Создание начального набора рекомендаций - используются модель машинного обучения, которая анализируют предпочтения пользователя и формируют список рекомендаций.
- Выделение категорий - определяются жанры для каждого рекомендованного фильма.
- Формирование диверсифицированного списка - создается новый список рекомендаций, включающий фильмы разных жанров.
- Ограничение количества рекомендаций - ограничивается количество фильмов в списке, например, до десяти, чтобы обеспечить разнообразие и избежать перегрузки информацией.

Четвёртый раздел В последнем разделе описывается практическая часть работы: инструменты, которые были использованы для реализации программы и WEB-приложения, какие данные выбраны для проверки работоспособности программы, а так же анализ полученных результатов.

Данные были взяты из открытых источников исследовательской группы GroupLens. Набор данных содержит около миллиона оценок, которые 6000 пользователей выставили 4000 фильмам. Эти данные предоставляют полез-

ную информацию для анализа рекомендаций фильмов и исследования проблемы информационного пузыря. Для исследования были взяты данные:

1. ratings.csv, в котором содержится информация о рейтингах, присвоенных пользователями различным фильмам;
2. movies.csv, в котором содержит информацию о фильмах, включая их идентификаторы, названия и жанры.

Структура ratings.csv выглядит следующим образом:

- userId - идентификатор пользователя, который поставил рейтинг, является числовым значением, уникальное для каждого пользователя;
- movieId - идентификатор фильма, который был оценен пользователем, числовое значение, уникальное для каждого фильма;
- rating- оценка, которую пользователь поставил фильму, значение представляет собой вещественное число от 0.5 до 5.0 с шагом 0.5, где 0.5 — самая низкая оценка, а 5.0 — самая высокая;
- Временная метка, представляющая время, когда был поставлен рейтинг.

В файле movies.csv присутствуют такие данные, как:

- movieId - идентификатор фильма;
- title - название фильма, строковое значение, содержащее название фильма и год его выпуска в скобках;
- genres - жанры фильма, строковое значение, содержащее жанры, разделенные символом |. Один фильм может принадлежать к нескольким жанрам.

Для реализации программы использовались библиотеки Python: Pandas, LightGBM, Scikit-learn, NumPy.

Для создания WEB-приложения использовались библиотеки Python: Dash, Plotly.

Приложение содержит следующие вкладки:

- Загрузка файлов;
- Данные по пользователям;
- Разнообразию;
- Метрики.

ЗАКЛЮЧЕНИЕ

Целью данной работы была разработка и анализ метода разрыва информационного пузыря в рекомендательной системе для улучшения качества рекомендаций и расширения жанрового разнообразия контента. Для достижения этой цели были выполнены следующие задачи: изучение понятий и типов рекомендательных систем, понимание концепции информационного пузыря, ознакомление с параметрами моделей, разработка рекомендательной системы с помощью ансамблевого метода LightGBM и диверсификации рекомендаций, а также формулирование выводов на основе полученных результатов.

В ходе исследования была создана рекомендательная система, основанная на ансамблевом методе LightGBM. Этот метод позволяет эффективно обрабатывать большие объемы данных и учитывать множество факторов, влияющих на предпочтения пользователей. Основное внимание было уделено проблеме информационного пузыря, когда пользователи получают рекомендации только на основе их предыдущих предпочтений, что ограничивает их возможности открывать новые жанры и виды контента.

Для разрыва информационного пузыря была внедрена стратегия диверсификации рекомендаций, что позволило расширить жанровое разнообразие предлагаемых фильмов. Результаты показали, что после диверсификации наблюдается увеличение жанрового разнообразия как для отдельных пользователей, так и для всей системы в целом. При этом средний предсказанный рейтинг для пользователей также повысился, что указывает на улучшение общего качества рекомендаций.

Однако анализ показателей Precision@10, Recall@10 и NDCG@10 до и после диверсификации выявил некоторые компромиссы. Хотя точность рекомендаций (Precision@10) и охват релевантных фильмов (Recall@10) несколько снизились после диверсификации, качество ранжирования рекомендаций (NDCG@10) осталось на высоком уровне. Это свидетельствует о том, что, несмотря на снижение точности, пользователи все еще получают высоко релевантные фильмы, но из более широкого спектра жанров.

Дальнейшие исследования могут быть направлены на улучшение методов диверсификации и повышение точности рекомендаций одновременно. Возможные направления включают использование гибридных моделей, ком-

бинирование различных моделей рекомендательных систем для достижения лучших результатов по точности и разнообразию; адаптивную диверсификацию, разработку методов, которые автоматически адаптируют уровень диверсификации в зависимости от предпочтений и поведения пользователя; введение новых метрик для более точного измерения качества рекомендаций и степени разрыва информационного пузыря; и интеграцию моделей, которые могут обучаться в режиме реального времени, учитывая изменения в предпочтениях пользователей.

Таким образом, предлагаемый подход позволяет уменьшить влияние информационных пузырей в работе рекомендательных систем и предоставлять пользователям более качественные и разнообразные рекомендации.

Основные источники информации:

- 1 Ricci, Francesco, Rokach, Lior and Shapira, Bracha, Introduction to recommender systems handbook, Springer, 2015.
- 2 Pariser, Eli, The filter bubble: What the Internet is hiding from you, Penguin UK, 2019.
- 3 Garimella, Kiran, Morales, Gianmarco De Francisci, Gionis, Aristides and Mathioudakis, Michael, Quantifying the effect of sentiment on information diffusion in social media, EPJ Data Science, 7(1), pp. 1–16, 2018, Springer.
- 4 Flaxman, Seth, Goel, Sharad and Rao, Justin M, Filter bubbles, echo chambers, and online news consumption, Public Opinion Quarterly, 80(S1), pp. 298–320, 2018, Oxford University Press.
- 5 Linden, Greg, Smith, Brent and York, Jeremy, Amazon.com recommendations: item-to-item collaborative filtering, IEEE Internet Computing, 7(1), pp. 76–80, 2002, IEEE.
- 6 Herlocker, Jonathan L., Konstan, Joseph A. and Riedl, John, Evaluating collaborative filtering recommender systems, ACM Transactions on Information Systems (TOIS), 22(1), pp. 5–53, 2004, ACM New York, NY, USA.
- 7 Filter Bubbles in Recommender Systems: Fact or Fallacy - A Systematic Review, 2023, URL: <https://arxiv.org/abs/2307.01221> (дата обращения: 20.05.2024).
- 8 Evolution of Filter Bubbles and Polarization in News, Springer, 2023, URL: <https://link.springer.com/article/10.1007/springer123456> (дата обращения: 20.05.2024).

- 9 Author, Bursting Filter Bubbles in a Digital Age: Opening Minds and Reducing Polarization, ScienceDirect, 2023, URL: <https://www.sciencedirect.com/science/article/pii/S123456789> (дата обращения: 20.05.2024).
- 10 GroupLens Research, MovieLens Datasets, 2023, URL: <https://grouplens.org/datasets/movielens/> (дата обращения: 20.05.2024).