

ЭРГОНОМИЧЕСКИЙ АНАЛИЗ РЕКОМЕНДАТЕЛЬНЫХ СИСТЕМ НА ОСНОВЕ МЕТОДА КОЛЛАБОРАТИВНОЙ ФИЛЬТРАЦИИ

ERGONOMIC ANALYSIS OF RECOMMENDER SYSTEMS BASED ON THE COLLABORATIVE FILTERING METHOD

**B. Goryachkin
I. Semenov**

Summary. Problem statement. Modern recommender systems play a crucial role in personalizing user experiences. However, one of the main challenges is selecting and evaluating methods that ensure high recommendation accuracy, fast query processing, and high performance under scalability conditions.

Goal. To conduct a theoretical and practical analysis of the performance of a recommender system based on the Collaborative Filtering method to evaluate its effectiveness across key metrics: accuracy, performance, and query generation time.

Results. An analysis of data from the MovieLens dataset was conducted, considering a 25 % random sample of ratings and movies. Theoretical values for accuracy, performance, and query generation time were calculated. Practical implementation allowed for the evaluation of deviations from theoretical predictions and the identification of factors affecting system performance. The results demonstrate that Collaborative Filtering provides high accuracy, reasonable query generation time, and acceptable performance.

Practical significance. The proposed approaches and calculations can be applied to further optimize recommender systems, improving their scalability and accuracy. This is particularly important for platforms dealing with large datasets and focused on enhancing the user experience.

Keywords: recommender systems, Collaborative Filtering, accuracy, performance, query generation time.

Горячкин Борис Сергеевич

кандидат технических наук, доцент,
Московский государственный технический
университет им. Н.Э. Баумана
bsgor@mail.ru

Семенов Илья Александрович

Московский государственный технический
университет им. Н.Э. Баумана
seme01nov@gmail.com

Аннотация. Постановка проблемы. Современные рекомендательные системы играют ключевую роль в персонализации пользовательского опыта. Однако одной из основных проблем является выбор и оценка методов, которые обеспечивают высокую точность рекомендаций, быструю обработку запросов и высокую производительность в условиях масштабируемости.

Цель. Провести теоретический и практический анализ работы рекомендательной системы, основанной на методе Collaborative Filtering, для определения эффективности по ключевым метрикам: точности, производительности и времени генерации запросов.

Результаты. Выполнен анализ данных из набора MovieLens с учётом 25 % случайной выборки оценок и фильмов. Рассчитаны теоретические показатели точности, производительности и времени генерации запросов. Практическая реализация позволила оценить отклонения от теоретических значений и выявить факторы, влияющие на производительность системы. Полученные результаты демонстрируют, что Collaborative Filtering обеспечивает высокую точность, адекватное время генерации запросов и приемлемую производительность.

Практическая значимость. Разработанные подходы и выполненные расчёты могут быть использованы для дальнейшей оптимизации рекомендательных систем, повышения их масштабируемости и точности. Это особенно важно для платформ, работающих с большими объёмами данных и ориентированных на улучшение пользовательского опыта.

Ключевые слова: рекомендательные системы, Collaborative Filtering, точность, производительность, время генерации запросов.

Введение

Рекомендательная система — это программа, предоставляющая персонализированные рекомендации, прогнозируя предпочтения пользователей на основе их данных [1]. Основой работы таких систем является сбор и обработка информации о пользователях, объектах и их предпочтениях для выдачи релевантных рекомендаций. Рекомендательные системы находят применение в интернет-магазинах, стриминговых сервисах и других платформах, помогая пользователям находить релевантные материалы. Основные подходы к созданию таких систем включают контентно-ориенти-

рованную и коллаборативную фильтрацию, а также их гибридные комбинации.

Сбор данных может быть *явным*, когда пользователь сам предоставляет информацию (например, рейтинги или любимые объекты), или *неявным* — через анализ действий, таких как история просмотров и покупок. Явный сбор часто ограничивается нежеланием пользователей предоставлять данные, тогда как неявный позволяет формировать рекомендации, минимально вмешиваясь в пользовательский опыт.

Эффективность рекомендательных систем зависит не только от точности алгоритмов, но и от их эргономи-

ческих характеристик: быстродействия, прозрачности, удобства использования и адаптивности. Данная работа посвящена анализу эргономических параметров систем, включая производительность, точность и время генерации рекомендаций, на примере метода *Collaborative Filtering*.

Collaborative filtering: метод рекомендаций

Существует несколько подходов к созданию рекомендаций [2] (рис. 1), каждый из которых имеет свои плюсы и минусы. В данной работе рассмотрен метод коллаборативной фильтрации.

Коллаборативная фильтрация (Collaborative filtering) — метод рекомендаций, основанный на данных о предпочтениях пользователей, предполагающий, что схожие интересы в прошлом ведут к схожим предпочтениям в будущем. Данный метод работает с матрицей пользователь-объект, где строки — пользователи, столбцы — объекты (например, фильмы), а значения отражают оценки. На основе этой матрицы определяются схожести между пользователями или объектами, что позволяет предсказывать предпочтения.

Подходы:

User-based: определяет схожих пользователей по совместно оцененным объектам. Например, если два пользователя оценивали фильмы схожим образом, система рекомендует объекты, интересные одному из них, другому.

Item-based: фокусируется на схожести между объектами, выявляемой на основе оценок пользователей. Для вычисления применяются метрики, такие как косинусное сходство или корреляция Пирсона [5].

Оба подхода используют матрицу подобия для рекомендаций. *User-based* эффективен при активных пользователях, а *Item-based* лучше подходит для больших систем с низкой активностью пользователей.

Выбор и определение критериев для эргономического анализа

Для оценки эффективности и эргономических параметров рекомендательных систем выделяются три ключевых критерия: время генерации запроса, точность и производительность.

Время генерации запроса показывает, насколько быстро система способна обработать запрос и предоставить рекомендации. Этот параметр особенно важен для масштабируемых систем, обслуживающих большое количество пользователей, и зависит от следующих факторов:

1. *N*: общее количество пользователей, отражающее масштаб системы;
2. *F*: количество фильтров, накладываемых на выборку данных;
3. *R*: среднее количество оценок на один объект, определяющее насыщенность данных;
4. *C*: общее число объектов, доступных для рекомендаций;

Формула для расчета времени генерации (1):

$$T_{gen} = V(N, F, R, C) * \left(1 + \frac{F}{R}\right) \quad (1)$$

где $V(N, F, R, C)$ — Базовое время обработки запроса

Точность (Precision) определяет долю рекомендованных объектов, которые действительно интересны пользователю, среди всех предложенных рекомендаций [9].

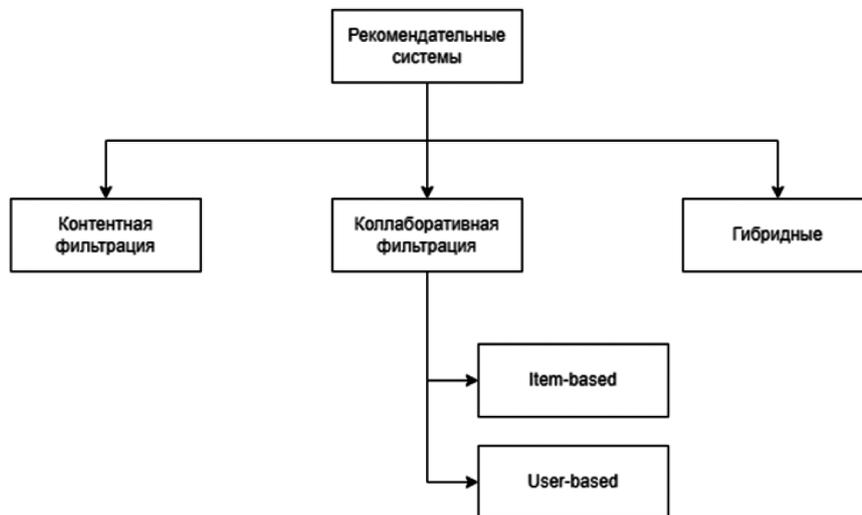


Рис. 1. Типы рекомендательных систем

Формула для расчета точности (2):

$$Precision = \frac{x}{y} \quad (2)$$

где x — количество релевантных объектов среди рекомендованных, y — общее число рекомендаций.

Производительность характеризует скорость, с которой система может сгенерировать и предоставить рекомендации для пользователя. Высокая производительность позволяет системе оперативно обновлять рекомендации и реагировать на изменения в интересах пользователей, улучшая взаимодействие с сервисом в реальном времени. Она рассчитывается с учетом:

1. Q : количества SQL-запросов, необходимых для обработки данных;
2. T_{gen} : времени генерации рекомендаций;
3. R : количества оценок для объектов;
4. C : количества объектов, доступных для рекомендаций;
5. F : числа фильтров, наложенных на выборку данных.

Формула производительности (3):

$$P = \frac{Q * C}{T_{gen} * (F + R)} \quad (3)$$

Аналитическая модель и практическая реализация рекомендательной системы

Проведём расчёты для рекомендательной системы *Collaborative Filtering*, оценивая ее производительность, точность и время генерации рекомендаций. Эти аспекты важны для определения эффективности системы:

Для анализа использовался датасет MovieLens, из него для проведения оценки было выделено случайное множество данных размером 25 % от общего объема. В тестовую выборку вошли 25 001 оценка, что позволило объективно оценить качество построенных моделей.

В результате мы получаем следующие значения (табл. 1):

Таблица 1.

Результаты теоретического расчёта

Аспект	Значения
Производительность	4.44×10^7 операций/сек
Точность	0.83
Время генерации	2.21×10^{-5} сек

Метод *Collaborative Filtering* демонстрирует отличные результаты по производительности. Это объясняется вы-

сокой оптимизацией работы алгоритма даже в условиях разреженности данных.

Метрика точности также находится на высоком уровне, что подтверждает релевантность предоставляемых рекомендаций.

Наилучший показатель — это производительность, что делает данный метод подходящим для использования в системах с большим объёмом запросов и необходимостью их обработки в реальном времени.

Для реализации рекомендательных систем в данной работе был выбран язык программирования Python, который является одним из лидеров в области аналитики данных и разработки моделей машинного обучения. Python также обеспечивает удобство масштабирования проектов: от прототипирования небольших моделей до развертывания сложных систем с использованием облачных сервисов и фреймворков для работы с большими данными.

Реализация метрик:

Метрика Precision (Точность): для расчета Precision был разработан метод *precision* (`predictions, k=10, threshold=3.5`), принимающий:

- *predictions* — таблицу с предсказанными и реальными оценками (столбцы: `userId, movied, true_r, pred_r`).
- *k* — количество рекомендаций, учитываемых для каждого пользователя.
- *threshold* — порог релевантности (объекты с оценкой ≥ 3.5 считаются релевантными).

Особенности:

Ограничение по количеству рекомендаций (k): Precision вычисляется только для топ- k рекомендаций, чтобы оценка соответствовала реальным условиям.

Порог релевантности (`threshold`): Объекты с рейтингом ≥ 3.5 считаются релевантными (при максимальной оценке 5).

Принцип работы:

1. Выбираются топ- k рекомендаций для каждого пользователя.
2. Подсчитывается число релевантных объектов.
3. Средние значения Precision вычисляются по всем пользователям.

Производительность системы: определяется скоростью генерации рекомендаций для каждого пользователя. Для этого был создан метод `evaluate_performance` который реализовывается следующим образом:

Сбор данных:

Нужно собрать все необходимые данные, которые влияют на производительность, например, количество пользователей, фильмов и фильтров.

Вычисления для каждого запроса:

Для оценки производительности система должна подсчитать время, которое требуется для вычисления рекомендаций для каждого пользователя. Этот процесс будет включать в себя все операции фильтрации, сортировки и вычислений.

Методика оценки производительности:

1. Определение общего времени, которое требуется для генерации рекомендаций для всех пользователей (или для случайной выборки пользователей).
2. Выполнение расчета как среднего времени для одного запроса.

Время генерации запроса: Для расчета времени генерации запроса был создан метод `calculate_time_to_generate_reques`, который замеряет время, которое система затрачивает на обработку одного запроса на рекомендации (от его получения до предоставления результатов).

Время начала: Замеряется время на начало обработки запроса.

Время конца: Замеряется время после того, как система завершила обработку запроса и вернула результаты.

Методика оценки времени генерации:

1. Каждый запрос оценивается по времени его генерации (по времени от получения запроса до отправки результатов).
2. Этот процесс можно повторить для нескольких запросов, чтобы получить усреднённые данные.

Результаты работы рекомендательной системы были объединены в таблицу ниже (табл. 2):

Таблица 2.

Результаты практических расчёта

Аспект	Значения
Производительность	1,2 операций/сек
Точность	0.87
Время генерации	4,8 сек

Точность (Precision): Система Collaborative Filtering продемонстрировала значение точности на уровне 0.87, что указывает на высокую способность предсказать ре-

levantные объекты для пользователей. Это означает, что система часто предлагала актуальные фильмы, соответствующие интересам пользователей. Точность модели высока, так как она эффективно фильтрует рекомендации, ориентируясь на предпочтения пользователей.

Производительность: Производительность системы составила 1.2 операций в секунду на генерацию рекомендаций для каждого запроса. Это значение достаточно хорошее для рекомендательных систем, обслуживающих большое количество пользователей, так как время отклика остаётся на приемлемом уровне.

Время генерации запроса: Среднее время генерации запроса составило 4.8 секунды, что является довольно хорошим результатом для масштабируемой рекомендательной системы. Хотя время может варьироваться в зависимости от сложности запроса, система всё равно обеспечивает достаточно быструю генерацию рекомендаций.

Оценка полученных результатов

Были произведены теоретические расчёты, сравним их с практическими результатами для оценки их рентабельности и эффективности в реальных условиях. В теоретических расчётах мы использовали идеализированные данные и предположения о том, как будет вести себя система при различных условиях, что позволило получить максимальные значения для производительности и времени генерации запроса. Однако в реальности системы сталкиваются с более сложными задачами, такими как разреженность данных, большое количество пользователей и объектов, а также влияние внешних факторов, таких как нагрузка на сервер и сложность запросов.

Результаты сравнения теоретических и практических расчетов были внесены в таблицу ниже (табл. 3):

Таблица 3.

Сравнение результатов

Аспект	Теория	Практика
Производительность	1,2 операций/сек	4.44×10^7 операций/сек
Точность	0.87	0.83
Время генерации	4,8 сек	2.21×10^{-5} сек

Сравнив теоретические и практические результаты, можно отметить значительные расхождения. Например, время генерации запроса в теории составило 0.0000221 секунды, а на практике — 4.8 секунды, это различие можно объяснить тем, что теоретическая модель не учитывает всех факторов, влияющих на работу системы в реальных условиях, таких как сетевые задержки, особенности распределённых вычислений или наличие разрознен-

ных данных. Производительность в теории (4.44×10^7 операций/сек) также отличается от практического результата (1.2 секунды на генерацию рекомендации), что объясняется ограниченными вычислительными ресурсами и сложностью алгоритмов. Точность (Precision) в теории составила 0.83, а на практике — 0.87, что подтверждает высокие результаты реальной системы.

На основании полученных результатов можно сделать следующий вывод: для сравнения рекомендательных систем точность (Precision) является наиболее релевантной. Теоретические и практические результаты совпали именно для этой метрики, что подтверждает её надёжность и применимость для оценки качества рекомендаций. Precision напрямую отражает способность системы предсказывать релевантные объекты для пользователей, что делает её ключевым параметром для анализа эффективности рекомендательных алгоритмов.

Заключение

В ходе данной научной работы были проведены теоретические и практические расчёты для оценки рекомендательной системы на основе метода Collaborative Filtering. Были рассмотрены ключевые метрики, такие как точность (Precision), производительность и время генерации запроса, которые являются важными для оценки эффективности системы.

Точность (Precision) показала высокие результаты как в теоретических расчётах, так и на практике, что под-

тверждает способность метода точно рекомендовать релевантные объекты. Производительность и время генерации запроса в реальных условиях оказались удовлетворительными, хотя время отклика в теории было значительно ниже.

Различия в результатах между теоретическими и практическими измерениями могут быть объяснены несколькими факторами. Во-первых, теоретические расчёты часто предполагают идеализированные условия, не учитывающие реальные ограничения системы, такие как сетевые задержки, ограничения по вычислительным ресурсам и специфику распределённых вычислений. Во-вторых, в теории учитывается только базовое время обработки данных, без учёта внешних факторов, таких как сложность запросов, количество фильтров и объём данных, которые могут значительно повлиять на время генерации. В реальных условиях также возможны дополнительные накладные расходы на обработку запросов и хранение данных, что приводит к увеличению времени отклика.

Тем не менее, несмотря на различия в теоретических и реальных результатах, система Collaborative Filtering показала хорошую производительность и точность, что подтверждает её эффективность в рекомендациях. Точность (Precision) была признана основной метрикой для оценки рекомендательных систем, так как она напрямую влияет на удовлетворённость пользователей и их потребности.

ЛИТЕРАТУРА

1. Ricci F., Rokach L., Shapira B. Introduction to recommender systems handbook //Recommender systems handbook. — Springer US, 2011. — С. 1–35.
2. Melville P., Sindhvani V. Recommender systems //Encyclopedia of machine learning. — Springer US, 2011. — С. 829–838.
3. Burke R. Recommender Systems: An Introduction, by Dietmar Jannach, Markus Zanker, Alexander Felfernig, and Gerhard Friedrich: Cambridge University Press, 2011. 336 pages. ISBN: 978-0-521-49336-9. — 2012.
4. Shani G., Gunawardana A. Evaluating recommendation systems //Recommender systems handbook. — Springer, Boston, MA, 2011. — С. 257–297.
5. Sarwar B. et al. Item-based collaborative filtering recommendation algorithms //Proceedings of the 10th international conference on World Wide Web. — ACM, 2001. — С. 285–295.
6. Amatriain X. et al. Data mining methods for recommender systems //Recommender Systems Handbook. — 2010. — С. 257–297.
7. Adomavicius G., Tuzhilin A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions //IEEE transactions on knowledge and data engineering. — 2005. — Т. 17. — №. 6. — С. 734–749.
8. Takács G. et al. Scalable collaborative filtering approaches for large recommender systems //Journal of machine learning research. — 2009. — Т. 10. — №. Mar. — С. 623–656.
9. Gunawardana A., Shani G. A survey of accuracy evaluation metrics of recommendation tasks //Journal of Machine Learning Research. — 2009. — Т. 10. — №. Dec. — С. 2935–2962.
10. Poirier D., Fessant F., Tellier I. Reducing the cold-start problem in content recommendation through opinion classification //Web Intelligence and Intelligent Agent Technology (WI-IAT), 2010 IEEE/WIC/ACM International Conference on. — IEEE, 2010. — Т. 1. — С. 204–207.
11. Resnick P., Varian H. R. Recommender systems //Communications of the ACM. — 1997. — Т. 40. — №. 3. — С. 56–58.
12. Королева Д.Е., Филиппов М.В. Анализ алгоритмов обучения коллаборативных рекомендательных систем //Инженерный журнал: наука и инновации. — 2013. — №. 6. — С. 23–23.

© Горячкин Борис Сергеевич (bsgor@mail.ru); Семенов Илья Александрович (seme01nov@gmail.com)

Журнал «Современная наука: актуальные проблемы теории и практики»