

МЕТРИКИ ОЦЕНКИ КАЧЕСТВА РАБОТЫ СИСТЕМ КОЛЛАБОРАТИВНОЙ ФИЛЬТРАЦИИ

Р.И. Ролгин

Самарский государственный аэрокосмический университет имени академика С.П. Королёва (национальный исследовательский университет) (СГАУ), Самара, Россия

Статья посвящена рекомендательным системам, которые представляют собой сравнительно новый класс программных продуктов, в задачу которого входит формирование или "предсказание" оценок пользователя для объектов (товаров интернет-магазина, фильмов, музыки и пр.) на основании уже имеющихся оценок этого пользователя для других объектов и оценок остальных пользователей системы. Решается задача построения списка рекомендаций для пользователя, учитывая его предпочтения и активность в системе. Коллаборативная фильтрация – один из основных методов, применяемых в такого рода системах. Приведены некоторые основные метрики, позволяющие оценить качество работы алгоритмов.

Ключевые слова: рекомендации, рекомендательные системы, коллаборативная фильтрация, метрики оценки качества.

Введение

Клиентская среда - это совокупность клиентов (пользователей, субъектов), регулярно пользующихся фиксированным набором сервисов (товаров, ресурсов, предметов, объектов). Предполагается, что действия клиентов протоколируются в электронном виде. Примерами действий являются: использование сервиса или покупка товара, оценивание (рейтингование) сервиса или товара, обращение за информацией, оплата услуг, выбор тарифного плана, участие в маркетинговой акции, получение бонуса от компании, отказ от обслуживания, и т. д.[1]

Рекомендательные системы - программы, которые пытаются предсказать, какие объекты (фильмы, музыка, книги, новости, веб-сайты) будут интересны пользователю, имея определенную информацию о его профиле. Зачастую реализуются на алгоритме коллаборативной фильтрации [2].

Рекомендательные системы анализируют интересы пользователей и пытаются предсказать, что именно будет наиболее интересно для конкретного пользователя в данный момент времени.

В настоящее время проблема рекомендательных систем сохраняет к себе большой интерес, так как в этой области остается много задач, решение которых обеспечит множество возможностей практического применения, что должно помочь пользователям справляться с громадным объемом информации, а также снабдить их инструментами выработки персонализированных рекомендаций.

1. Основные понятия коллаборативной фильтрации

Главным методом персонализированного информационного фильтрования является коллаборативная фильтрация. По существу оно автоматизирует процесс рекомендации: объекты рекомендуются пользователю на основании опыта взаимодействия с объектом других людей.

Коллаборативная фильтрация, совместная фильтрация (англ. collaborative filtering) - это один из методов построения прогнозов (рекомендаций) в рекомендательных системах, использующий известные предпочтения (оценки) группы пользователей для прогнозирования неизвестных предпочтений другого пользователя. Его основное допущение состоит в следующем: те, кто одинаково оценивали какие-либо предметы в прошлом, склонны давать похожие оценки другим предметам и в будущем. Например, с помощью коллаборативной фильтрации музыкальное приложение способно прогнозировать, какая музыка понравится пользователю, имея неполный список его предпочтений (симпатий и антипатий). Прогнозы составляются индивидуально для каждого пользователя, хотя используемая информация собрана от многих участников. Тем самым коллаборативная фильтрация отличается от более простого подхода, дающего усреднённую оценку для каждого объекта интереса, к примеру, базирующуюся на количестве поданных за него голосов [3].

При коллаборативной фильтрации используется информация о поведении пользователей в прошлом; например, информация о покупках или оценках. В этом случае не имеет значения, с какими типами объектов ведётся работа, но при этом могут учитываться неявные характеристики, которые сложно было бы учесть при создании профиля.

Основная проблема этого типа рекомендательных систем - «холодный старт». Проблема холодного старта - новые предметы или пользователи представляют большую проблему для рекомендательных систем, т.к. новый пользователь ещё не успел проявить активность в системе и о нём практически ничего неизвестно, а новый объект ещё никто не оценил. Частично проблему помогает решить подход, основанный на анализе содержимого, так как он полагается не на оценки, а на атрибуты, что помогает включать новые предметы в рекомендации для пользователей. Однако проблему с предоставлением рекомендации для нового пользователя решить сложнее.

Для решения такого рода концептуальной проблемы применяется принцип суперпозиции рекомендательных систем или гибридные рекомендательные системы. Гибридные системы сочетают в себе достоинства всех составляющих её систем и этим может сгладить недостатки использования какого-то одного алгоритма. В таких системах списки рекомендаций формируются несколькими алгоритмами, затем эти сформированные рекомендации объединяются по некоторым правилам, например, могут применяться средние оценки или взвешенное среднее всех "предсказанных" результатов и т.п.

Учитываться при формировании списка рекомендаций помимо явных действий (рейтингов), могут и неявные действия пользователей в системе, например, переходы по ссылкам. Сбор такого рода данных не представляет трудностей, но не всегда можно просто отразить эти данные на вектор пользовательских предпочтений. Переход по ссылке на объект лишь означает, что пользователь хотел подробнее узнать об объекте, но мы не можем точно сказать, понравился он ему или нет [4].

2. Задача коллаборативной фильтрации

Пусть U - множество субъектов (клиентов, пользователей: users) в некой взаимосвязанной системе - клиентской среде. Примерами таких сред могут быть социальные сети, интернет-магазины, поисковые машины, торговые сети, операторы сотовой связи и др.

Положим I - множество объектов клиентской среды (ресурсов, товаров, предметов: items).

У - множество транзакции в клиентской среде. Примерами транзакции являются: использование сервиса или покупка товара, оценивание (рейтингование) сервиса или товара, обращение за информацией, оплата услуг, выбор тарифного плана, участие в маркетинговой акции, получение бонуса от компании, отказ от обслуживания, и т. д.

Необходимо по существующим данным решить задачу: формирование списка рекомендаций для субъекта u , $u \in U$ или для объекта i , $i \in I$.

Предполагаемый рейтинг пользователя для объекта получается путём использования предыдущих оценок других "похожих" на текущего пользователей. "Похожими" пользователи называются, когда их оценки одним и тем же товарам сходны по своей величине. Чаще всего для оценки сходства применяется косинусная мера, приведенная в формуле 1.

$$\text{sim}(\vec{A}, \vec{B}) = \cos(\vec{A}, \vec{B}) = \frac{\vec{A} \bullet \vec{B}}{\|\vec{A}\| * \|\vec{B}\|} \quad (1)$$

Формируемые системой оценки для каждого из объектов будут показателями, на основании которых можно рекомендовать объект (чем больше предполагаемая оценка, тем больше объект понравится пользователю).

3. Оценка качества работы алгоритмов

Для оценки качества работы существует множество метрик качества. В основном, это метрики оценки точности предполагаемого значения и реального, если таковой имеется. Рассмотрим некоторые из них: MAE, RMSE.

MAE

MAE (Mean Absolute Error, пер. средняя абсолютная ошибка) – ошибка оценивается как разница между предсказанием и реальной оценкой по модулю (2).

$$\text{MAE} = \frac{\sum_{i \in n} |P_i - R_i|}{n} \quad (2)$$

RMSE

RMSE (Root Mean Squared Error, пер. средняя квадратичная ошибка) – ошибка вычисляется как корень из суммы квадратов разниц между предсказываемым значением и реальным значением (3).

$$\text{RMSE} = \sqrt{\frac{\sum_{i \in n} (P_i - R_i)^2}{n}} \quad (3)$$

Так же можно оценить еще некоторые характеристики рекомендательных систем, уже основываясь на всем списке рекомендаций. Причём необходимо иметь данные о том, какие позиции в списке релевантные (соответствуют запросу), а какие нет. Обозначим длину всего списка рекомендаций как L, множество соответствующих рекомендаций – T, множество несоответствующих (нерелевантных) позиций в списке – F. Тогда характеристику точности можно представить в виде формулы (4).

$$\text{Accuracy} = \frac{\|T\|}{L} \quad (4)$$

Введем еще одно множество G – множество элементов, которые должны были быть порекомендованы, но в списке не оказались.

Тогда характеристику полноты можно представить в виде формулы (5).

$$Recall = \frac{\|T\|}{\|T\| + \|G\|} \quad (5)$$

Вывод

Таким образом, с использованием приведенных мер, можно контролировать качество используемых методов коллаборативной фильтрации, или других методов, применяемых в рекомендательных системах. Варьируя параметры используемых алгоритмов, необходимо стремиться к минимальному значению ошибки. Так же цели, которые стоят перед разработчиками такого рода систем – получить меры точности и полноты близкие к единице, но такое не всегда получается, и, в таком случае, приходится идти на компромисс между тем точностью и полнотой.

Заключение

В статье приведены понятия, применяемые при разработке рекомендательных систем и приведены метрики, которые применяются для оценки качества работы алгоритмов коллаборативной фильтрации.

Литература

1. Воронцов, К.В. Анализ клиентских сред [Электронный ресурс]. - http://www.machinelearning.ru/wiki/index.php?title=Анализ_клиентских_сред (дата обращения 10.11.2015).
2. Николенко, С.А. Рекомендательные системы [Текст]/ С.А. Николенко - СПб: Изд-во Центр Речевых Технологий, 2012. - 53 с.
3. Сиаоюн, Су. Обзор техник коллаборативной фильтрации [Электронный ресурс]. - <http://downloads.hindawi.com/journals/aai/2009/421425.pdf> (дата обращения 10.11.2015).
4. Kazienko, P. Personalized Ontology-based Recommender Systems for Multimedia Objects / P. Kazienko, K. Musial. – Berlin: Springer Verlag, 2010. – 380 p.