

МЕТОДЫ МАТРИЧНОЙ ФАКТОРИЗАЦИИ ДЛЯ СИСТЕМ РЕКОМЕНДАЦИИ

Мойсюк-Дранько П. А., Ревотюк М. П.

Кафедра информационных технологий автоматизированных систем, Белорусский государственный университет информатики и радиоэлектроники
Минск, Республика Беларусь

E-mail: moysyukdrankopasha@gmail.com, rmp@bsuir.by

Рассматриваются общие технические сведения рекомендательных систем и алгоритма матричной факторизации

ВВЕДЕНИЕ

Современные потребители забиты выбором. Электронные ритейлеры и контент-провайдеры предлагают огромный выбор продуктов, с беспрецедентными возможностями для удовлетворения разнообразных особых потребностей и вкусов. Подбор наиболее подходящих продуктов для потребителей является ключом к повышению удовлетворенности пользователей и лояльности. Поэтому все больше розничных продавцов проявляют интерес к системам рекомендаций, которые анализируют шаблоны интереса пользователей к продуктам, чтобы дать персонализированные рекомендации, соответствующие вкусу пользователя. Поскольку хорошие персонализированные рекомендации могут добавить еще одно измерение к опыту пользователя, лидеры электронной коммерции, такие как Amazon.com и Netflix, сделали системы рекомендаций важной частью своих вебсайтов.

I. ОБЩИЕ СВЕДЕНИЯ

В широком смысле, системы рекомендаций основаны на одной из двух стратегий. Подход контент-фильтрации создает профиль для каждого пользователя или продукта, чтобы охарактеризовать его природу. Профили позволяют программам ассоциировать пользователей с соответствующими продуктами. Конечно, контент-ориентированные стратегии требуют сбора внешней информации, которая может быть недоступна или которую трудно собрать. Альтернатива контент-фильтрации основывается только на прошлом поведении пользователя, например, на предыдущих транзакциях или рейтингах продуктов, без необходимости создания явных профилей. Этот подход известен как коллаборативная фильтрация. Коллаборативная фильтрация анализирует отношения между пользователями и взаимозависимости между продуктами для выявления новых ассоциаций между пользователями. Двумя основными областями коллаборативной фильтрации являются методы соседства и модели скрытых факторов. Методы соседства сосредоточены на вычислении отношений между элементами или, в качестве альтернативы, между поль-

зователями. Элементно-ориентированный подход оценивает предпочтения пользователя по отношению к элементу на основе оценок "соседей" элементов одним и тем же пользователем. Соседями продукта являются другие продукты, которые, как правило, получают аналогичные рейтинги, если их оценивает один и тот же пользователь. Некоторые из наиболее успешных реализаций латентных факторных моделей основаны на матричной факторизации. В своей базовой форме матричная факторизация характеризует как элементы, так и пользователей по векторам факторов, выведенных из рейтинговых моделей элементов. Высокое соответствие между элементным и пользовательским факторами приводит к рекомендации. Эти методы стали популярными в последние годы благодаря сочетанию хорошей масштабируемости и точности прогнозирования. Кроме того, они предлагают большую гибкость для моделирования различных реальных ситуаций. Рекомендующие системы полагаются на различные типы входных данных, которые часто помещаются в матрицу с одним измерением, представляющим пользователей, и другим измерением, представляющим элементы, представляющие интерес. Наиболее удобными данными являются высококачественные явные обратные связи, которые включают в себя явный ввод данных пользователями относительно их интереса к продуктам. Одним из достоинств матричной факторизации является то, что она позволяет включать дополнительную информацию. Когда явная обратная связь недоступна, системы референтов могут делать выводы о предпочтениях пользователя, используя неявную обратную связь, которая косвенно отражает мнение, наблюдая за поведением пользователя.

II. БАЗОВАЯ МАТРИЧНАЯ МОДЕЛЬ ФАКТОРИЗАЦИИ

Матричные факторизационные модели отображают как пользователей, так и элементы в единое латентное факторное пространство размерности f таким образом, что взаимодействия между пользователем и элементами моделируются как внутренние продукты в этом

пространстве. Соответственно, каждый элемент i ассоциируется с вектором $q_i \in \mathbb{R}^f$ и каждый пользователь u связан с вектором $p_u \in \mathbb{R}^f$

Для данного пункта i , элементы q_i измеряют степень, в которой данный пункт обладает этими факторами, положительными или отрицательными. Для данного пользователя u , элементы p_u измеряют степень интереса, который пользователь имеет к элементам, высоким по соответствующим факторам, опять же, положительным или отрицательным. Получившийся точечный продукт, $q_i^T p_u$ фиксирует взаимодействие между пользователем u и объектом i - общий интерес пользователя к характеристикам объекта. Это приблизительно соответствует рейтингу пользователя u пункта i , который обозначается r_{ui} , что приводит к оценке

$$\hat{r}_{ui} = q_i^T p_u \quad (1)$$

Главная задача заключается в вычислении соотношения между каждым элементом и пользователем с учетом векторов $q_i, p_u \in \mathbb{R}^f$. После того, как рекомендующая система выполнит это отображение, она может легко оценить рейтинг, который пользователь присвоит любому элементу с помощью уравнения 1.

Такая модель тесно связана с сингулярной величиной декомпозиции (SVD), хорошо зарекомендовавшей себя методикой выявления скрытых семантических факторов при поиске информации. Применение SVD в области совместной фильтрации требует факторинга матрицы рейтинга пользовательского элемента. Это часто вызывает трудности из-за высокой доли пропущенных значений, вызванной редкостью в матрице рейтингов пользовательского элемента. Обычное SVD не определено, когда знания о матрице неполные. Более того, неосторожное обращение только к относительно небольшому количеству известных элементов очень склонно к перепогонке.

Ранние системы полагались на приписывание, чтобы заполнить недостающие рейтинги и сделать матрицу рейтинга плотной [2]. Однако приписывание может быть очень дорогостоящим, так как оно значительно увеличивает объем данных. Кроме того, неточные вменения могут значительно исказить данные. Поэтому в более поздних работах [3-6] предлагалось моделировать только непосредственно наблюдаемые рейтинги, избегая при этом перепополнения через упорядоченную модель. Для изучения факторных векторов (p_u и q_i) система минимизирует ошибку регуляризованного квадрата на множестве известных рейтингов:

$$\min_{q, p} \sum_{(u, i) \in \mathbb{K}} (r_{ui} - q_i^T p_u)^2 + \lambda (\|q_i\|^2 + \|p_u\|^2) \quad (2)$$

Здесь K - это набор пар (u, i) , по которым известен r_{ui} (тренировочный набор).

Система знакомится с моделью, подгоняя ее под ранее наблюдавшиеся рейтинги. Однако цель состоит в том, чтобы обобщить эти предыдущие рейтинги таким образом, чтобы предсказать будущие, неизвестные рейтинги. Таким образом, система должна избегать перепогонки наблюдаемых данных путем регуляризации выученных параметров, величины которых оштрафованы. Константа λ контролирует степень регуляризации и обычно определяется перекрестной проверкой. Вероятностным основанием для регуляризации является "Вероятностный матричный фактор"[7] Руслана Салахутдинова и Андрея Мниха.

III. АЛГОРИТМЫ ОБУЧЕНИЯ

Два подхода к минимизации уравнения 2 - это стохастический градиентный спуск и чередующиеся наименьшие квадраты (ALS).

Вывод

Методы матричной факторизации стали доминирующей методикой среди рекомендующих совместную фильтрацию. Опыт работы с наборами данных, такими как данные Netflix Prize, показал, что они обеспечивают точность, превосходящую классические методы "ближайшего соседа". В то же время, они предлагают компактную модель с эффективной памятью, которую системы могут относительно легко изучить. Еще более удобным является то, что модели могут естественным образом интегрировать многие важные аспекты данных, такие как множественные формы обратной связи, временная динамика и уровни уверенности.

СПИСОК ЛИТЕРАТУРЫ

1. Goldberg D., Using Collaborative Filtering to Weave an Information Tapestry / D. Goldberg // Comm. ACM. - 1992. - Vol. 32, pp. 61-70.
2. Application of Dimensionality Reduction in Recommender System - A Case Study / B. M. Sarwar // ACM Press. - 2000
3. Netflix update: Try This at Home [Electronic resource] / Funk S., Dec. 2006. Mode of access: <http://sifter.org/~simon/journal/20061211.html>. - Date of access: 03.08.2020.
4. Factorization Meets the Neighborhood: A Multifaceted Collaborative Filtering Model / Y. Koren // ACM Press. -2008. -Proc. 14 ACM SIGKDD Int'l Conf. Knowledge Discovery and Data Mining. - pp. 426-434.
5. Improving Regularized Singular Value Decomposition for Collaborative Filtering / A. Paterek // ACM Press. - 2007. -Proc. KDD Cup and Workshop. -pp. 39-42
6. Major Components of the Gravity Recommendation System / G. Takacs et al. // SIGKDD Explorations, vol.9. -2007. - pp. 80-84
7. Probabilistic Matrix Factorization / R. Salakhutdinov and A. Mnih // ACM Press. -2008. -Proc. Advances in Neural Information Processing Systems 20 (NIPS 07). - pp. 1257-1264 <http://www.inform.ind.edu/PBIO/>. - Date of access: 14.09.2012.