

Многокритериальные контекстно-управляемые рекомендующие системы: модель и метод*

А. В. Смирнов, А. В. Пономарев

Санкт-Петербургский институт информатики и автоматизации РАН (СПИИРАН), г. Санкт-Петербург, Россия

Аннотация. Предложены модель и метод формирования контекстно-управляемых рекомендаций, применимые в том случае, когда отношение пользователя к объекту фиксируется не с помощью одного интегрального критерия (оценка, общий рейтинг), а с помощью набора частных критериев, оценивающих разные аспекты объекта. Предлагаемые модель и метод позволяют решить две основные задачи применения рекомендующих систем: ранжировать объекты по предсказанной субъективной интегральной полезности при заданных весах частных критериев и ранжировать объекты по предсказанной субъективной интегральной полезности в заданном контексте.

Ключевые слова: рекомендующие системы, многокритериальная оптимизация, линейная свертка, коллаборативная фильтрация, контентная фильтрация, контекстно-управляемые системы.

DOI 10.14357/20718594190303

Введение

Под рекомендующими системами (РС) принято понимать класс программных систем, которые за счет математического моделирования предпочтений пользователя облегчают задачу выбора объектов некоторого заранее определенного вида (преимущественно в областях, где основания такого выбора носят субъективный характер). В связи с развитием информационно-коммуникационных технологий и быстрым ростом количества доступной информации важность систем такого класса только увеличивается, поскольку они, наряду с системами информационного поиска, позволяют снизить информационную нагрузку на человека. В настоящее время без РС редко обходятся сайты электронной коммерции [1-4], широко они применяются в сфере туризма [5-7] и других областях [8-10].

Наиболее распространенными подходами к построению РС являются коллаборативная фильтрация и контентная фильтрация. В первом случае единственной информацией, используемой РС, являются оценки (рейтинги) объектов (книг, фильмов, достопримечательностей) пользователями, а во втором – дополнительно используются еще атрибуты объектов (жанр книги или фильма, архитектурный стиль достопримечательности и прочие). Типовой задачей РС в таком случае является попытка «предсказания» неизвестной оценки и ранжирование неоцененных пользователем объектов в соответствии с предсказанной оценкой. Долгое время развитие РС связывалось с разработкой новых методов такого предсказания на основе имеющейся базы оценок, дающих более высокие значения стандартных мер качества рекомендаций (среднеквадратичная ошибка предсказания, точность и полнота). Однако в данном направлении наметился определенный

* Работа выполнена при финансовой поддержке бюджетной темы СПИИРАН 0073-2019-0005.

✉ Пономарев Андрей Васильевич. E-mail: ponomarev@iias.spb.su

кризис, преодоление которого связывается с повышением качества рекомендаций за счет использования дополнительной информации. Здесь, в частности, возможно три пути: 1) гибридизация методов (как в рамках одного подхода, так и нескольких [7]); 2) учет зависимости полезности объекта от текущего контекста пользователя; 3) расширение модели предпочтений пользователя за счет лучшего «понимания» структуры оценки объекта.

В данной статье предлагается решение, сочетающее элементы первого и второго путей (хотя, предлагаемые методы могут быть использованы и в рамках какой-либо схемы гибридизации). Действительно, в большинстве случаев исходной информацией для РС являются скалярные оценки, характеризующие общее отношение пользователя к объекту (товару, услуге). При этом не учитываются два важных момента: во-первых, в разных ситуациях оценка пользователем одного и того же объекта может отличаться (попытка включить в модель понятие ситуации и ее формализованного описания (контекста) предпринимается в контекстно-зависимых РС), во-вторых, сама оценка объекта может носить многокритериальный характер («хорош по одному критерию, но недостаточно хорош по другому»). В статье предлагаются модель, метод и алгоритм функционирования РС, в которых, помимо интегральной оценки, обрабатываются несколько оценок объектов по различным критериям и происходит учет контекстной информации.

Это позволяет решать две задачи: во-первых, если структура предпочтений пользователя известна (явно задана пользователем), то становится возможным поиск объектов, наилучшим образом соответствующих данной структуре предпочтений. Во-вторых, если структура предпочтений неизвестна, то на основе связи между контекстом и структурой предпочтений оценивается важность различных критериев для пользователя в определенном контексте.

1. Краткая характеристика современных исследований

В настоящее время две передовые ветви в области РС – контекстно-зависимые (контекстно-управляемые) и многокритериальные развиваются практически независимо. Исследования

в области контекстно-зависимых РС развиваются в рамках трех основных подходов к учету контекста [1]: предварительной контекстной фильтрации, контекстной пост-фильтрации и моделирования контекста. Метод, предложенный в рамках данной статьи, находится ближе всего к предварительной контекстной фильтрации, так как использует для обучения модели только то подмножество множества оценок, которое было получено в определенных условиях (контексте). Вместе с тем, в современных работах по контекстно-зависимым РС рассматриваются только скалярные оценки объектов [1, 13], возможность учета векторных оценок представляет собой существенное отличие от работ в этой области.

В рамках исследований в области многокритериальных РС наметилось два основных подхода – в рамках первого подхода РС осуществляет свертку критериев, участвующих в векторной оценке объекта, используя либо веса, заданные экспертом (специфичные для предметной области), либо веса, оцененные на основе анализа действий пользователя (индивидуальную структуру предпочтений) [15]. В рамках второго подхода свертка не производится, вместо этого оцениваются индивидуальные значения каждого из критериев для объектов, которые пользователь не оценил, и на основе этих оценок формируется множество Парето рекомендуемых объектов [14]. Предлагаемый в статье метод относится к первому подходу. Это позволяет применять его в широком классе систем (например, электронной коммерции), не предполагающих, что пользователь будет тратить существенное время на анализ всего множества Парето (которое может содержать достаточно много элементов), а сконцентрируется на нескольких предложенных вариантах.

2. Модель предпочтений пользователя для многокритериальной РС

Пусть U – множество пользователей, а I – множество объектов. Для обозначения пользователя и объекта будем использовать символы u и i соответственно. Отношение пользователя u к объекту i характеризуется значениями k частных критериев $\rho_{u,i}^{(1)}, \dots, \rho_{u,i}^{(k)}$ и интегральной оценкой полезности (привлекательности) в




Рис. 1. Схема взаимного влияния различных элементов модели

определенных условиях $r_{u,i,c}$, где $c \in C$ – текущий контекст. Контекст представляет собой формализованное описание текущего состояния пользователя (его цели, характеристик используемого устройства и прочие) и ситуации и может описываться набором контекстных атрибутов. Множество C , таким образом, это множество допустимых сочетаний значений контекстных атрибутов.

В рамках предлагаемой модели предполагается, что $r_{u,i,c}$ определяется значениями частных критериев, являясь их линейной комбинацией:

$$r_{u,i,c} = \pi_{u,c}^{(1)} \rho_{u,i}^{(1)} + \dots + \pi_{u,c}^{(k)} \rho_{u,i}^{(k)},$$

где $\pi_{u,c}^{(j)}$ – вес j -го частного критерия в интегральной оценке при контексте c .

Таким образом, данная модель предполагает, что оценки объекта по частным критериям $\rho_{u,i}^{(j)}$ не зависят от контекста и характеризуют либо собственно объект (например, вес или цена товара), либо какой-то из аспектов восприятия объекта пользователем (сюжет или подбор актеров в фильме, внешний вид товара). При этом в различных ситуациях (определяемых контекстом) вклад частных критериев в интегральную оценку полезности может различаться, поэтому частные критерии входят в формулу вычисления интегральной оценки с зависящими от контекста коэффициентами $\pi_{u,c}^{(j)}$. Схема взаимного влияния элементов модели приведена на Рис. 1.

Назначение многокритериальной РС сводится к решению двух основных задач:

1) Формирование множества объектов, обладающих наибольшей интегральной полезностью при заданных весах частных критериев.

2) Формирование множества объектов, обладающих наибольшей интегральной полезностью при заданном контексте.

Сложность решения этих задач связана с тем, что для значительного числа объектов неизвестны $\rho_{u,i}^{(j)}$ и $r_{u,i,c}$, а при решении задачи 2 неизвестны также веса частных критериев $\pi_{u,c}^{(j)}$ для пользователя u в контексте c .

3. Метод формирования рекомендаций

Метод формирования рекомендаций позволяет решить обе задачи многокритериальных РС, выделенные в Разделе 2. Для этого предлагается два алгоритма. В первом веса критериев считаются известными (например, они получены явным образом от пользователя) и алгоритм предсказывает интегральную оценку и ранжирует по ней объекты. Во втором алгоритме веса считаются неизвестными, и алгоритм оценивает веса частных критериев в определенном контексте на основе истории.

3.1. Формирование рекомендаций при известных весах частных критериев

Как уже указывалось, критерии могут быть как объективными (характеризовать сам объект), так и субъективными (характеризовать тот или иной аспект оценочного суждения пользователя относительно объекта). В первом случае значения частных критериев могут быть получены как некоторая функция от значений атрибутов объекта (например, цена, вес). Обработка подобных критериев сближает подобные системы с системами контентной фильтрации, в которых рекомендации осуществляются на ос-

нове сопоставления структурированных описаний объектов. Напротив, оценка объекта по субъективным критериям (зрелищность, сюжет, подбор актеров, визуальная привлекательность и пр.) может быть осуществлена только пользователем, и в процессе формирования такой оценки он опирается на свои эстетические, утилитарные или другие предпочтения. Таким образом, оценка объектов по субъективным критериям раскрывает предпочтения пользователя.

Поскольку получение оценок от пользователя требует внимания последнего и специально посвященного этому времени, в большинстве случаев непосредственно от пользователей может быть получена относительно небольшая доля таких оценок. Для решения же первой поставленной задачи, заключающейся в формировании множества объектов, обладающих наибольшей интегральной полезностью, необходимо иметь возможность оценить интегральную полезность для всех объектов, а для этого необходимо оценить значения всех частных критериев.

Для решения задачи заполнения пропусков в значениях частных критериев предлагается применить классические алгоритмы РС. Поскольку в рамках рассматриваемой модели на значения частных критериев контекст не оказывает влияния, то это могут быть базовые рекомендующие модели, не учитывающие текущий контекст. Таким образом, итоговая РС является композитной, включающей в себя набор частных РС для различных критериев. Кроме того, при создании подобной РС предлагается использовать информацию о природе (субъективной или объективной) каждого из критериев. Для заполнения значений объективных критериев, определяемых атрибутами объекта, предлагается использовать методы контентных рекомендующих систем (например, [16]). Для заполнения же пропусков в значениях некоторого субъективного критерия, определяемых предпочтениями пользователей, предлагается использовать алгоритмы коллаборативной фильтрации [17]. В таких алгоритмах на основе анализа множества известных оценок объектов пользователями делается попытка «предсказать» оценки объектов, с которыми пользователь не взаимодействовал. Принципиальным отличием предлагаемого подхода является то, что на практике существующие алгоритмы коллаборативной фильтрации обычно применяются для заполнения пропусков в ин-

тегральных оценках, в то время как в данной статье предлагается использовать их для заполнения пропусков в значениях частных субъективных критериев. Это позволяет добиться более стабильных «предсказаний», поскольку оценки частных критериев являются более «сфокусированными», на их значение влияют меньше факторов, и, следовательно, пользователям оказывается значительно проще их оценить.

Таким образом, предлагается следующий алгоритм решения задачи формирования множества объектов, обладающих наибольшей интегральной полезностью при заданных весах частных критериев.

Входные данные:

u_r – пользователь, для которого необходимо сформировать рекомендации;

$\pi^{(1)}, \dots, \pi^{(k)}$ – веса частных критериев;

$\{\rho_{u,i}^{(1)}\}, \dots, \{\rho_{u,i}^{(k)}\}$ – матрицы известных значений частных критериев.

Алгоритм 1:

1. **for** $j \in [1, k]$:
2. **for** $i \in I$:
3. **if** **defined**($\rho_{u,i}^{(j)}$):
4. $\hat{\rho}_{u,i}^{(j)} \leftarrow \rho_{u,i}^{(j)}$
5. **else**:
6. $\hat{\rho}_{u,i}^{(j)} \leftarrow \text{partialRecommender}_j(u_r, i)$
7. **for** $i \in I$:
8. $\hat{r}_{u,i} \leftarrow \sum_{j=1}^k \pi^{(j)} \hat{\rho}_{u,i}^{(j)}$
9. **return** $\text{ordered}(I, \hat{r}_{u,i}, \text{"desc"})$

В строках 1-6 алгоритма производится оценка значений частных критериев с использованием частных рекомендующих моделей (*partialRecommender_j*). Полученные оценки $\hat{\rho}_{u,i}^{(j)}$ используются для вычисления интегральной полезности каждого объекта (строка 8). Результатом является список объектов, упорядоченный по убыванию интегрального критерия полезности $\hat{r}_{u,i}$, подготовленный функцией *ordered()*.

3.2. Метод учета контекста

Для решения второй задачи (формирования списка объектов, обладающих наибольшей полезностью при заданном контексте) необходимо установить связь между контекстом и важностью частных критериев для пользователя в данном контексте. После чего задача может

быть сведена к предыдущей. Для анализа влияния контекста на предпочтения пользователя предлагается использовать разновидность метода предварительной контекстной фильтрации [11], суть которой сводится к тому, что сначала отбирается подмножество оценок, в которое входят только те оценки, которые были получены в данном контексте (при данных условиях), а потом к этому подмножеству применяются какие-либо алгоритмы формирования рекомендаций. Поскольку в соответствии с предлагаемой моделью предпочтений частные критерии не зависят от контекста, а важность частных критериев (их вес в интегральной полезности) и интегральная полезность – зависят, то для оценки весов частных критериев в заданном контексте можно использовать только известные оценки интегральной полезности $r_{u,i,c}$. Причем значения частных критериев $\rho_{u,i}^{(j)}$ для соответствующих объектов могут и отсутствовать. В этом случае они могут быть заменены оценками $\hat{\rho}_{u,i}^{(j)}$, полученными с помощью частных рекомендующих моделей (*partialRecommender_j*).

Пусть $W = \{r_{u,i,c}\}$ – множество интегральных оценок, присвоенных пользователем u различным объектам в контексте c .

1) Рассмотрим случай, когда $|W| \geq k$. В этом случае предлагается коэффициенты важности частных критериев находить в результате решения задачи минимизации функции ошибки:

$$E_W(\pi_{u,c}^{(1)}, \dots, \pi_{u,c}^{(k)}) = \sum_{r_{u,i,c} \in W} \left(r_{u,i,c} - \left(\pi_{u,c}^{(1)} \hat{\rho}_{u,i}^{(1)} + \dots + \pi_{u,c}^{(k)} \hat{\rho}_{u,i}^{(k)} \right) \right)^2.$$

Значения весов $\hat{\pi}_{u,c}^{(1)}, \dots, \hat{\pi}_{u,c}^{(k)}$, при которых функция ошибки принимает минимальное значение, подаются на вход Алгоритма 1 для построения ранжированного списка объектов.

2) Если $|W| < k$, то известных интегральных оценок оказывается недостаточно для определения k весов. В этом случае предлагается использовать неперсонализированные оценки коэффициентов, полученные по формуле, аналогичной предыдущему случаю, однако в качестве множества, на котором происходит минимизация функции ошибок, используется множество всех оценок в данном контексте.

Таким образом, предлагается следующий алгоритм формирования множества объектов, обладающих наибольшей интегральной полезностью.

Входные данные:

u_r – пользователь, для которого необходимо сформировать рекомендации;

c' – текущий контекст;

$W = \{r_{u,i,c'}\}$ – множество оценок, полученных от пользователя u_r в контексте c' .

Алгоритм 2:

1. **if** $|W| \geq k$:

2. $\hat{\pi}_{u_r,c'}^{(1)}, \dots, \hat{\pi}_{u_r,c'}^{(k)} \leftarrow \text{minimize}(E_W(\pi_{u_r,c'}^{(1)}, \dots, \pi_{u_r,c'}^{(k)}))$

3. **else**:

4. $\hat{\pi}_{u_r,c'}^{(1)}, \dots, \hat{\pi}_{u_r,c'}^{(k)} \leftarrow \text{minimize}(E_{c'}(\pi_{u_r,c'}^{(1)}, \dots, \pi_{u_r,c'}^{(k)}))$

5. **return** *Algorithm1*($u_r, \hat{\pi}_{u_r,c'}^{(1)}, \dots, \hat{\pi}_{u_r,c'}^{(k)}$)

Функция *minimize()* возвращает значение аргумента, доставляющий минимальное значение заданной функции. В строке 2 происходит минимизация функции ошибки на оценках, полученных от данного пользователя, а в строке 4 – на всех оценках, полученных в контексте c' . Для получения итогового ранжирования найденный набор коэффициентов передается в Алгоритм 1.

4. Экспериментальное исследование

В связи с тем, что сама постановка задачи построения многокритериальных РС достаточно нова, в данной области не сформировалось общепринятых «бенчмарков» (наборов данных, широко используемых для сопоставления качества рекомендующих алгоритмов). Поэтому экспериментальное исследование предложенных модели и метода было проведено с использованием синтетического набора данных.

Сформированный синтетический набор данных включает информацию о 100 пользователях, 100 объектах и 1752 фактах оценивания объекта пользователем (при генерации набора данных количество объектов, оцененных пользователем, выбиралось случайным образом в диапазоне от 10 до 25). Объект описывается шестью атрибутами (вещественные числа в диапазоне от 0 до 1). Каждый факт оценивания содержит три частных оценки (целые числа

от 1 до 10) и интегральную оценку. Процесс оценивания объекта пользователем моделировался следующим образом. Предполагалось, что оценка объекта по каждому из частных критериев зависит от значений подмножества атрибутов объекта, причем подмножества, влияющие на оценки по разным частным критериям, не пересекаются. Для получения частной оценки вычислялась линейная свертка значений атрибутов, оказывающих влияние на эту оценку (веса в этой свертке являются индивидуальными характеристиками пользователя), а затем множество значений такой свертки, полученных для разных объектов, оцениваемых пользователем, масштабировалось в пространство шкалы оценок (т.е. в диапазон от 1 до 10). Масштабирование, в частности, отражает тот факт, что пользователь при формировании оценки опирается, в первую очередь, на имеющийся опыт, сопоставляя каждый из объектов с другими известными ему. Интегральная оценка определяется как линейная свертка частных оценок (коэффициенты этой линейной свертки зависят от индивидуальных характеристик пользователя).

С использованием сформированного набора данных предложенный метод был сопоставлен с популярными рекомендующими алгоритмами: алгоритмом коллаборативной фильтрации, основанным на факторизации матриц (CF) [18], и алгоритмом контентной фильтрации, основанным на измерении сходства между объектами (CBF) [17]. При реализации предложенного авторами метода (далее MCF) для предсказания частных оценок была также использована контентная фильтрация. При этом определение меры сходства между объектами использовало инфор-

мацию о том, какие атрибуты объектов оказывают влияние на частную оценку (остальные атрибуты мерой сходства не учитывались). Перед сопоставлением была проведена оптимизация гиперпараметров каждого из сравниваемых алгоритмов. Под гиперпараметрами алгоритма понимаются параметры, значения которых задаются до обучения модели и не изменяются в процессе обучения. Гиперпараметрами сравниваемых алгоритмов являются: у CF – количество скрытых факторов, у CBF и моделей частных оценок, используемых в MCF, – количество используемых «ближайших соседей» и требование к минимальному значению меры сходства при поиске «ближайших соседей».

Рекомендующие модели оценивались с помощью среднеквадратичной ошибки (root mean square error, RMSE) предсказания интегральной оценки. Для более достоверного сопоставления моделей была применена кросс-валидация по пяти блокам [19], т.е. набор данных был разбит на пять частей и в ходе каждого из пяти проведенных экспериментов с моделью одна часть была использована в качестве тестовой выборки, а четыре других – в качестве обучающей. На Рис. 2 показан разброс значений среднеквадратичной ошибки каждого из алгоритмов (каждая точка соответствует среднеквадратичной ошибке исследуемого метода на одном из блоков). Видно, что предложенный метод (MCF) на данном наборе позволяет, в целом, добиться меньшей ошибки (сопоставимая ошибка оказалась только на одном из блоков в CBF). Это происходит из-за того, что MCF позволяет использовать дополнительную информацию о предпочтениях пользователя, выраженную в его оценках по частным критериям.




Рис. 2. Сравнение рекомендующих моделей

Заключение

В статье рассмотрена проблема построения многокритериальных контекстно-управляемых РС, в которых отношение пользователя к объекту фиксируется не с помощью одного интегрального показателя (оценка, общий рейтинг), а с помощью набора частных критериев, оценивающих разные аспекты объекта.

Предложена модель предпочтений пользователя для таких систем, в соответствии с которой интегральная оценка объекта пользователем представляется в виде линейной свертки частных оценок по различным критериям, а веса критериев в этой свертке являются зависимыми от контекста.

Предложен метод формирования рекомендаций, состоящий из двух частей: предсказание интегральной оценки объектов при известных весах частных критериев (в том числе, при наличии пропусков в значениях оценки объектов по частным критериям) и вычисление весов частных критериев в определенном контексте на основе истории действий пользователя.

Экспериментальное исследование с помощью синтетического набора данных показало, что предложенные метод и модель позволяют эффективно использовать информацию о структуре предпочтений пользователя, выраженную в виде оценок объектов по частным критериям.

Разработанная модель и метод позволяют решать основную задачу РС (формирование списка объектов, в наибольшей степени удовлетворяющих субъективным предпочтениям пользователя) в двух вариантах: при наличии явно заданных весов частных критериев и с учетом контекста.

Литература

1. Sivapalan S. et al. Recommender systems in e-commerce // World Automation Congress (WAC), 2014. – IEEE, 2014. – С. 179-184.
2. Mbugua A. W., Omondi A. O. An Application of association rule learning in recommender systems for e-Commerce and its effect on marketing // IEEE Pan African Conference on Science, Computing, and Telecommunications. – 2017.
3. Paraschakis D., Nilsson B. J., Holländer J. Comparative evaluation of top-n recommenders in e-commerce: An industrial perspective // 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA). – IEEE, 2015. – С. 1024-1031.
4. Zhou M. et al. Micro behaviors: A new perspective in e-commerce recommender systems // Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. – ACM, 2018. – С. 727-735.
5. Gavalas D. et al. Mobile recommender systems in tourism // Journal of network and computer applications. – 2014. – Vol. 39. – Pp. 319-333.
6. Borràs J., Moreno A., Valls A. Intelligent tourism recommender systems: A survey // Expert Systems with Applications. – 2014. – Vol. 41, issue 16. – Pp. 7370-7389.
7. Кашевник А.М., Пономарев А.В., Смирнов А.В. Полимоделный контекстно-управляемый рекомендуемый сервис в области туризма: подход и архитектура // Известия РАН. Теория и системы управления. – 2017. – № 2. – С. 77-91.
8. Karimi M., Jannach D., Jugovac M. News recommender systems – Survey and roads ahead // Information Processing & Management. – 2018. – Vol. 54, issue 6. – Pp. 1203-1227.
9. Amato F., Moscato V., Picariello A., Piccialli F. SOS: A multimedia recommender system for online social networks // Future Generation Computer Systems. – 2019. – Vol. 93. – Pp. 914-923.
10. Teran L., Mensah A.O., Estorelli A. A literature review for recommender systems techniques used in microblogs // Expert Systems with Applications. – 2018. – vol. 103. – Pp. 63-73.
11. Adomavicius G., Sankaranarayanan R., Sen S., Tuzhilin A. Incorporating contextual information in recommender systems using a multidimensional approach // ACM Trans. Inf. Syst. – 2005. – Vol. 23, no. 1. – Pp. 103-145.
12. Villegas N. M. et al. Characterizing context-aware recommender systems: A systematic literature review // Knowledge-Based Systems. – 2018. – Vol. 140. – Pp. 173-200.
13. Haruna K. et al. Context-Aware Recommender System: A Review of Recent Developmental Process and Future Research Direction // Applied Sciences. – 2017. – Vol. 7, no. 12. – Pp. 1211.
14. Ribeiro M., Lacerda A., de Moura E., Veloso A., Ziviani N. Multi-objective pareto-efficient approaches for recommender systems // ACM Transactions on Intelligent Systems and Technology. – 2013. – 9(1). – Pp. 1–20.
15. Adomavicius G., Kwon Y. New recommendation techniques for multicriteria rating systems // IEEE Intelligent Systems. – 2007. – 22(3). – Pp. 48–55.
16. Pazzani M., Billsus D. Content-based recommendation systems // The Adaptive Web. – Springer, 2007. – Pp. 325-341.
17. Ricci F. et al. Recommender Systems Handbook. – 2nd edition. – Springer, 2015. – 1003 pgs.
18. Koren Y. Matrix Factorization Techniques for Recommender Systems // Computer. – 2009. – Vol. 42, issue 8. – Pp. 30-37.
19. Gareth J., Witten D., Hastie T., Tibshirani R. An Introduction to Statistical Learning: with Applications in R. – Springer, 2013.

Multi-Criteria Context-Driven Recommender Systems: Model and Method

A .V. Smirnov, A. V. Ponomarev

St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences (SPIIRAS), St. Petersburg, Russia

Abstract. A model and method of generating context-driven recommendations for recommendation systems with multi-criteria ratings are proposed, applicable when the user's attitude to the object is fixed not by using one integral criterion (assessment, overall rating), but by using a set of individual criteria that evaluate different aspects of the object. The proposed model and method allow to solve two main problems of using recommender systems: to rank objects according to the predicted subjective integral utility with given weights of partial criteria and to rank objects according to the predicted subjective integral utility in a given context.

Keywords: recommendation systems, recommender systems, multi-criteria optimization, weighted sum method, collaborative filtering, content filtering, context-driven systems.

DOI 10.14357/20718594190303

References

1. Sivapalan, S. et al. 2014. Recommender systems in e-commerce. World Automation Congress (WAC). 179–184.
2. Mbugua, A.W., and A.O. Omondi. 2017. An Application of association rule learning in recommender systems for e-Commerce and its effect on marketing. IEEE Pan African Conference on Science, Computing, and Telecommunications.
3. Paraschakis, D., B.J. Nilsson, and J. Holländer. 2015. Comparative evaluation of top-n recommenders in e-commerce: An industrial perspective. 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA). 1024–1031.
4. Zhou, M. et al. 2018. Micro behaviors: A new perspective in e-commerce recommender systems. Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining. 727–735.
5. Gavalas, D. et al. 2014. Mobile recommender systems in tourism. Journal of network and computer applications. 39:319–333.
6. Borràs, J., A. Moreno, and A. Valls. 2014. Intelligent tourism recommender systems: A survey. Expert Systems with Applications. 41(16):7370–7389.
7. Kashevnik, A., A. Ponomarev, and A. Smirnov. 2017. A Multimodel Context-Aware Tourism Recommendation Service: Approach and Architecture. Journal of Computer and System Sciences International. 56(2):245–258.
8. Karimi, M., D. Jannach, and M. Jugovac. 2018. News recommender systems – Survey and roads ahead. Information Processing & Management. 54(6):1203–1227.
9. Amato, F., V. Moscato, A. Picariello, and F. Piccialli. 2019. SOS: A multimedia recommender system for online social networks. Future Generation Computer Systems. 93:914–923.
10. Teran, L., A.O. Mensah, and A. Estorelli. 2018. A literature review for recommender systems techniques used in microblogs. Expert Systems with Applications. 103:63–73.
11. Adomavicius, G., R. Sankaranarayanan, S. Sen, and A. Tuzhilin. 2005. Incorporating contextual information in recommender systems using a multidimensional approach. ACM Trans. Inf. Syst. 23(1):103–145.
12. Villegas, N.M. et al. 2018. Characterizing context-aware recommender systems: A systematic literature review. Knowledge-Based Systems. 140:173–200.
13. Haruna, K. et al. 2017. Context-Aware Recommender System: A Review of Recent Developmental Process and Future Research Direction. Applied Sciences. 7(12):1211.
14. Ribeiro, M., A. Lacerda, E. de Moura, A. Veloso, and N. Ziviani. 2013. Multi-objective pareto-efficient approaches for recommender systems. ACM Transactions on Intelligent Systems and Technology. 9(1):1–20.
15. Adomavicius, G., Y. Kwon. 2007. New recommendation techniques for multicriteria rating systems. IEEE Intelligent Systems. 22(3):48–55.
16. Pazzani, M., and D. Billsus. 2007. Content-based recommendation systems. In The Adaptive Web. 325–341.
17. Ricci, F. et al. 2015. Recommender Systems Handbook. 2nd edition. Springer. 1003 p.
18. Koren, Y. 2009. Matrix Factorization Techniques for Recommender Systems. Computer. 42(8):30–37.
19. Gareth, J., D. Witten, T. Hastie, and R. Tibshirani. 2013. An Introduction to Statistical Learning: with Applications in R. Springer.