

Садовская Анастасия Владимировна, магистрант, Московский

государственный технический университет им. Н.Э. Баумана

Афанасьев Арсений Геннадьевич, ассистент, Московский государственный

технический университет им. Н.Э. Баумана

Афанасьев Геннадий Иванович, кандидат технических наук, доцент,

Московский государственный технический университет им. Н.Э. Баумана

ПОВЫШЕНИЕ РАЗНООБРАЗИЯ РЕКОМЕНДАЦИЙ ЗА СЧЕТ ПЕРСОНАЛИЗАЦИИ

Аннотация: Рекомендательные системы завоевывают все большую известность из-за увеличения информации, доступной через Интернет. Основным аспектом качества такой системы долгое время считалась точность рекомендаций, которая связана с тем, насколько рекомендации актуальны для каждого отдельного пользователя. Однако повышенное внимание уделяется разнообразию как важному аспекту качества рекомендаций. Поскольку персонализация диверсификации была упущена из виду, мы предлагаем метод для выполнения процесса диверсификации персонализированным образом, позволяя контролировать компромисс между разнообразием и точностью. Кроме того, мы также представляем технику рекомендаций, которая использует прошлые предпочтения пользователя и рейтинги опытных экспертов по категориям в процессе генерации рекомендаций. Мы объединяем эти два метода, чтобы обеспечить более персонализированный опыт диверсификации.

Ключевые слова: разнообразие, персонализация, рекомендательные системы.

Abstract: Recommender systems are gaining more and more prominence due to the increase in information available over the Internet. The main aspect of the quality

of such a system has long been considered the accuracy of recommendations, which is related to how relevant the recommendations are to each individual user. However, increased attention is being paid to diversity as an important aspect of the quality of recommendations. Since the personalization of diversification has been overlooked, we propose a method for performing the diversification process in a personalized manner, allowing control over the trade-off between variety and accuracy. In addition, we also present a recommendation technique that uses the user's past preferences and ratings of experienced category experts in the recommendation generation process. We combine these two methods to provide a more personalized diversification experience.

Keywords: diversity, personalization, recommender systems.

Введение

Обилие информации быстро возросло с развитием технологий. Следовательно, людям стало трудно легко найти то, что они хотят. Рекомендательные системы направляют людей в персонализированной манере к интересным или полезным предметам в пространстве возможных вариантов [1]. Это выполняется путем тщательного наблюдения и записи прошлых предпочтений пользователей. Один из способов, которым пользователи указывают свои предпочтения в отношении элементов, — это оценка элементов. Основываясь на этих прошлых предпочтениях, рекомендательные системы прогнозируют рейтинг, который пользователь даст невидимому элементу, и предсказывает, насколько релевантным будет определенный элемент для пользователя. Такие системы оценивались на основе точности вынесенных рекомендаций. Но точность не является единственным фактором, который устанавливает удовлетворенность пользователей и качество рекомендаций [2]. Разнообразие и новизна рекомендаций также имеют решающее значение для повышения эффективности процесса генерации рекомендаций [2].

Разнообразие относится к тому, насколько различны элементы в списке по отношению друг к другу [3], обычно основываясь на свойствах элементов. Разнообразие уменьшает избыточность рекомендаций, тем самым расширяя

диапазон вариантов, предлагаемых пользователю.

Основная часть

Одним из известных традиционных методов рекомендаций является контент-ориентированный, который генерирует рекомендации пользователю на основе того, насколько элемент похож на функции элементов, которые пользователь предпочитал в прошлом. Другим методом является пользовательская коллаборативная фильтрация (*UserCF*), которая основана на аналогичной концепции соседей и рекомендует элементы, которые были предпочтительны другими пользователями с похожими вкусами.

Хотя индивидуальное разнообразие, т.е. предоставление разнообразного набора предметов человеку, считается важным, максимизация разнообразия приводит к жертве точности, поскольку разнообразие и точность являются двумя конкурирующими целями. Таким образом, компромисс между ними должен контролироваться. Постфильтрационные подходы учитывают этот аспект и генерируют диверсифицированный список рекомендаций, жадно выбирая k элементов, которые максимизируют заданный критерий, из списка рекомендаций, состоящего из списка рекомендаций, состоящего из n ($n > k$) элементов, сгенерированных рекомендательной системой. Большинство из этих подходов постфильтрации [5, 6], которые контролируют разнообразие и компромисс точности, основаны на критериях максимальной предельной релевантности (*MMR*) [8], приведенных в (1), используемых для поиска диверсификация результата. В (1) отношение документа к запросу пользователя обозначается $sim_1(D_i, Q)$, а сходство между двумя документами обозначается $sim_2(D_i, D_j)$ и λ используется в качестве параметра, который контролирует разнообразие и компромисс релевантности.

$$MMR = \arg \max_{D_i \in R \setminus S} [\lambda sim_1(D_i, Q) - (1 - \lambda) \max_{D_j \in S} sim_2(D_i, D_j)] \quad (1)$$

Хотя большинство из этих существующих подходов к диверсификации неперсонализированы и осуществляют одинаковую процедуру диверсификации для каждого пользователя, опросы пользователей [7] показывают, что

склонность к разнообразию не одинакова для каждого человека. Следовательно, процедура диверсификации также должна осуществляться в персонализированной манере. Таким образом, мы определяем, что персонализированная стратегия диверсификации должна учитывать диверсификацию списка рекомендаций, включая либо более новые элементы, либо более релевантные элементы на основе прошлого опыта пользователя. Существует стратегия [9], которая диверсифицирует список рекомендаций пользователя в отношении категории товаров, на основе которого прошлые предпочтения пользователя наиболее разнообразны. Хотя это включает в себя некоторую персонализацию, она не учитывает, должна ли диверсификация придавать большее значение новым элементам или соответствующим элементам, основанным на персонализации.

Методология

В этом разделе мы попробуем представить дизайн предлагаемого подхода. Персонализированная техника диверсификации представляет собой постфильтрационный подход и состоит из двух основных компонентов, а именно: *ExpertRec* и *PersonalizedDiv*. Мы используем *ExpertRec* для создания списка рекомендаций, который будет использоваться в качестве входных данных для *PersonalizedDiv*, чтобы сформировать окончательный диверсифицированный список рекомендаций.

Экспертный рекомендательный движок (*ExpertRec*)

Expert – based Recommender Engine (ExpertRec) — это метод рекомендаций, который прогнозирует рейтинги для элементов на основе как прошлых предпочтений пользователя, так и оценок экспертов и генерирует список рекомендаций. Эксперты определяются как пользователи, которые имеют большой опыт работы в определенной категории предметов. Например, в домене кино пользователь, который оценил около ста романтических фильмов, имеет более высокий опыт и знания в жанре романтики, чем пользователь, который оценил около ста фильмов самых разных жанров. Таким образом, мы определяем экспертов как пользователей, которые показали низкие

разнообразные предпочтения в прошлом, и мы идентифицируем их как экспертов в категории, которую они имеют. Больше опыта, о чем свидетельствует наибольшее число предметов, относящихся к этой категории. *ExpertRec* также учитывает, насколько релевантный элемент для пользователя, основываясь на том, насколько категории элемента похожи на категории элементов прошлых предпочтений пользователя. Чтобы предсказать рейтинги на основе оценок экспертов и прошлых предпочтений пользователя и тем самым сформировать окончательный список рекомендаций, *ExpertRec* проходит несколько шагов, которые представлены далее.

Измерение разнообразия предпочтений пользователей

Первым этапом *ExpertRec* является поиск разнообразия предпочтений каждого пользователя. Для этого мы сначала создаем профиль предпочтений категории пользователя (C_u) и используем его для измерения разнообразия. C_u указывает, насколько пользователь предпочитает каждую категорию элементов. Например, в домене кино C_u указывает, насколько вы предпочитаете приключенческие, романтические жанры и т.д. Вычисляем $C_{u,c}$ в соответствии с (2) для каждой категории товара c и строим C_u ($C_{u,c} \in C_u$). Профиль пользователя U_u включает в себя все элементы, которые u оценил, и он представлен U_u . Набор категорий, к которым принадлежит элемент j , задается I_j , например, это указывает на набор жанров фильма j .

$$C_{u,c} = \frac{\sum_{i \in U_u, c \in I_i} \frac{1}{|I_i|}}{|U_u|} \quad (2)$$

Затем мы адаптируем энтропию Шеннона, как в (3) для вычисления разнообразия прошлых предпочтений пользователя D_u . Здесь $|C|$ указывает общее количество категорий элементов в наборе данных.

$$D_u = - \sum_{i=1}^{|C|} C_{u,c} \log_{|C|} C_{u,c} \quad (3)$$

Создание группы экспертов

На этапе создания группы экспертов выбираются эксперты и создаются группы экспертов для каждой категории предметов. В *ExpertRec* пользователи, которые продемонстрировали низкое разнообразие в своих предпочтениях, были

идентифицированы как эксперты в категории, которую они оценили больше всего. Для выбора экспертов мы сначала выбираем пользователей, которые имеют более низкий D_u заданного порога T ($0 \leq D_u, T \leq 1$). Из этих пользователей мы выбираем экспертов для каждой категории, определяя категорию с наибольшей вероятностью предпочтения (т.е. $\operatorname{argmax} C_{u,c}$) в C_u этого пользователя. Если пользователь имеет одинаковую самую высокую вероятность предпочтения для более чем одной категории, мы идентифицируем этого пользователя как эксперта во всех этих категориях. Таким образом, в конце этого этапа, для каждой из категорий предметов, у нас есть группа экспертов, которая включает экспертов этой категории.

Прогнозирование релевантности

Прогнозирование релевантности — это заключительный этап *ExpertRec*, который предсказывает релевантность элемента для пользователя. Чтобы предсказать рейтинг для элемента, мы объединяем оценку, которую мы получаем, учитывая прошлые предпочтения пользователя, и оценку, которую мы получаем от экспертов. Мы получаем окончательную оценку релевантности для элемента j из (4), где $UScore_j$ — это оценка, основанная на прошлых предпочтениях пользователя, а $EScore_j$ - оценка, основанная на оценках, данных экспертами. Деление на 2 указывает на одинаковый вклад обеих баллов.

$$RScore_j = \frac{UScore_j + EScore_j}{2} \quad (4)$$

Оценка на основе пользователя

Оценка на основе пользователей ($UScore$) получается из измерения сходства на основе контента. Основная концепция $UScore_j$ заключается в том, чтобы рассчитать, насколько пользователь хотел бы элемент j , основываясь на том, насколько пользователю нравятся категории элемента j , как указано в прошлых оценках пользователя. Рассматривая оценки, которые пользователь дал элементам, которые похожи на элемент j , мы можем предсказать $UScore_j$ в соответствии с (5).

$$UScore_j =$$

$$UScore_j = \frac{\sum_{i \in U_u \ \& \ I_i \cap I_j \neq \emptyset} \sum_{c \in \{I_i \cap I_j\}} \frac{r_{u,i}}{|I_i|}}{\sum_{i \in U_u \ \& \ I_i \cap I_j \neq \emptyset} 1} \quad (5)$$

Мы представляем оценку, которую пользователь u дал элементу i , по $r_{u,i}$. В конечном итоге $UScore$ даст оценку того, насколько важен элемент для пользователя на основе прошлых предпочтений пользователя.

Оценка на основе экспертов

Оценка на основе экспертов ($EScore$) — это оценка, полученная на основе оценок экспертов. Чтобы рассчитать $EScore_j$ для элемента j , мы сначала определим группу экспертов для категорий элементов j . Например, если предмет j имеет жанры романтики и триллера, мы сначала выбираем группу экспертов по романтике и группу экспертов по триллерам из ранее сгенерированного набора экспертных групп. После этого мы выбираем экспертов из тех групп, которые оценили товар j . Один раз набор экспертов-членов, которые оценили пункт j , заданный EM_j , идентифицируется, все их рейтинги агрегируются для получения $EScore$ согласно (6).

$$EScore_j = \frac{\sum_{u \in EM_j} r_{u,j}}{|EM_j|} \quad (6)$$

ExpertRec прогнозирует рейтинги для товаров, которые пользователь не оценил, на основе $RScore$, приведенного в (4), и элементы упорядочены в соответствии с прогнозируемыми рейтингами, а топ N позиции рекомендуются пользователю.

ExpertRec использует не только прошлые рейтинги пользователей, но и рейтинги экспертов. Следовательно, даже если пользователь не оценил какой-либо предмет, похожий на рекомендуемый товар, он все равно будет рекомендован пользователю, если эксперты оценили его хорошо. Следовательно, *ExpertRec*, в отличие от других традиционных рекомендательных систем, усиливает разнообразие, позволяя добавлять новые элементы в список кандидатов пользователя. Также безопасно рекомендовать такие новые предметы, поскольку этот предмет был рекомендован не только

обычным пользователем, но и группой экспертов, которые имеют более высокий опыт работы с этим предметом. категория.

Создавая список рекомендаций как с актуальными, так и с новыми элементами, *ExpertRec* поддерживает *PersonalizedDiv* для проведения диверсификации персонализированным образом. После создания первоначального списка рекомендаций из *ExpertRec*, мы подаем его в качестве входных данных для *PersonalizedDiv* и генерируем окончательный список рекомендаций.

Персонализированный модуль диверсификации

Основная задача, выполняемая модулем персонализированной диверсификации (*PersonalizedDiv*), заключается в создании списка рекомендаций для пользователя, диверсифицированного персонализированным образом, позволяя контролировать компромисс между разнообразием и актуальностью. Основная гипотеза *PersonalizedDiv* заключается в следующем: с одной стороны, пользователи, которые имеют опыт работы с различными категориями предметов и отдают им предпочтение, имеют склонность к различным новым элементам. Таких пользователей можно идентифицировать по их весьма разнообразному профилю (C_u). Таким образом, *PersonalizedDiv* диверсифицирует списки рекомендаций таких пользователей более новыми элементами, которые разнообразны в отношении прошлых предпочтений рассматриваемого пользователя.

С другой стороны, пользователи, которые показали предпочтения только для нескольких категорий элементов, которые могут быть распознаны по менее разнообразному профилю, которым они обладают, как правило, предпочитают категории элементов, аналогичные тем, которые у них есть. ранее показывал предпочтение. Таким образом, *PersonalizedDiv* диверсифицирует списки рекомендаций таких пользователей большим количеством элементов, похожих на то, что пользователь потреблял раньше. Разнообразие профиля предпочтений категории пользователя (C_u) также может иметь среднее значение, указывая на то, что пользователь предпочитает различные новые элементы, а также

предметы, похожие на его прошлые предпочтения. Диверсификация списка рекомендаций такого пользователя путем включения как новых, так и релевантных элементов также регулируется *PersonalizedDiv*. Следовательно, целью *PersonalizedDiv* является получение такого персонализированного диверсификационного поведения, которое диверсифицирует окончательный список рекомендаций пользователя на основе d различий прошлых предпочтений пользователя.

PersonalizedDiv — это постфильтрационный подход, сформулированный как проблема оптимизации, которая генерирует окончательный список рекомендаций путем итеративного выбора k элементов из списка элементов-кандидатов из n ($n > k$) элементов, сгенерированных из *ExpertRec*, которые максимизируют нашу целевую функцию (7). Это более подробно объясняется в [10].

Используемая нами целевая функция, приведенная в пункте (7), принимает максимальную предельную релевантность (*MMR*) [9]. Он использует параметр λ ($0 \leq \lambda \leq 1$) для контроля компромисса между разнообразием и релевантностью. В (7) $RScore_i$ представляет рейтинг для элемента i , предсказанный рекомендательной системой, используемый для создания списка элементов-кандидатов. Когда список кандидатов генерируется из *ExpertRec*, $RScore_i$ укажет рейтинг, рассчитанный по (4). Максимальная оценка, которую пользователь может дать элементу в разрешенной рейтинговой шкале, указывается *MaxPossibleRating*, а $RScore_i$ делится на него, чтобы получить нормализованный балл релевантности. Следовательно, первый компонент (7) связан с релевантностью элемента для пользователя. Второй компонент (7), который является $PDiv(i, R, C_u, D_u)$, рассчитывается по (8) и коррелирует с разнообразием окончательного списка рекомендаций. Поэтому очевидно, что λ может быть использовано для контроля разнообразия и компромисса релевантности.

$$PersonalizedDIV(i, R, C_u, D_u) = \lambda \frac{RScore_i}{MaxPossibleRating} + (1 - \lambda) PDiv(i, R, C_u, D_u) \quad (7)$$

Если мы дополнительно проясним (8), мы можем понять, что он состоит из двух основных компонентов; W -персонализированный, вычисляемый по (9) и $div(i, R)$. Эти компоненты вместе дают оценку, связанную с персонализированной диверсификацией. Далее мы разворачиваем каждый из этих компонентов.

$$PDiv(i, R, C_u, D_u) = W_{personalized} * div(i, R) \quad (8)$$

$$W_{personalized} = \frac{\sum_{c \in I_i} |D_u - C_{u,c}|}{|I_i|}; 0 \leq W_{personalized} \leq 1 \quad (9)$$

Наша концепция персонализированной диверсификации заключается в персонализированном весе ($W_{personalized}$), приведенном в (9). Чем выше разница между разнообразием прошлых предпочтений пользователя, D_u и прошлым опытом пользователя с категорией c , которая является категорией элемента i , выше вероятность добавления элемента в окончательный список. Разница будет выше, если D_u высокий, а i является новым элементом, обозначенным более низким значением $C_{u,c}$ для категорий i или если D_u низкий, а i является релевантным элементом, обозначенным более высоким $C_{u,c}$. Дополнительные сведения о $W_{personalized}$ можно найти в [10]. Весовые значения $W_{personalized}$ рассчитываются соответствующим образом, чтобы включить персонализированную диверсификацию.

Чтобы сохранить разнообразие окончательного списка рекомендаций, мы умножаем $W_{personalized}$ на $div(i, R)$ в (8). $div(i, R)$ дает оценку того, насколько разнообразным будет список R , если мы добавим в него элемент i . Он вычисляется как обратный агрегированному попарному сходству между элементом i и каждым элементом j в списке R . Сходство между двумя элементами вычисляется с помощью сходства *Jaccard*.

Экспериментальные результаты

Для проведения экспериментов по оценке предложенного нами подхода мы использовали набор данных *MovieLens100k*, который содержит пользовательские рейтинги к фильмам и жанрам фильмов. Наша оценка состояла из двух фаз экспериментов. Первая серия экспериментов была направлена на

оценку *ExpertRec*, а вторая — на изучение *PersonalizedDiv*. Мы использовали традиционный алгоритм *UserCF*, доступный в Apache Mahout, настроенный с размером окрестности 50 и сходством корреляции Пирсона в качестве меры сходства пользователей. Выборочный размер первоначального рекомендательного перечня кандидатов составлял 100 пунктов, а окончательный список рекомендаций — 10.

Эксперименты для *ExpertRec*

Мы провели эксперименты, чтобы оценить, является ли наш подход *ExpertRec* конкурентоспособным в отношении точности прогнозирования рейтинга и для содействия разнообразию в рекомендательных списках. Перед проведением количественных экспериментов мы должны были определить пороговое значение T , которое будет использоваться в *ExpertRec*. Мы проанализировали набор данных и заметили, что при $T < 0,4$ экспертов не было или их было очень мало. Таким образом, мы выбрали $T = 0,8$, так как это средняя точка возможного диапазона значений (0,5 – 1,0).

Мы использовали *UserCF* в качестве базовой линии для сравнения *ExpertRec* с и сгенерировали список элементов кандидатов из обоих методов. Для измерения точности прогнозирования рейтинга мы использовали метрику *RMSE* и использовали метод удержания, сохраняя 70% оценок каждого пользователя для построения обучающего набора и оставшиеся 30% для тестового набора и проводили валидацию в течение 5 раундов. Итоговый балл *RMSE* был средним *RMSE* каждого раунда. Для измерения разнообразия мы использовали попарную метрику *ILD@k* [7] с Jaccard Similarity в качестве меры подобия. Мы сгенерировали списки элементов даты *candi* для каждого пользователя, используя выбранную технику рекомендаций, т.е. либо *ExpertRec*, либо *UserCF*. Затем мы измерили разнообразие сгенерированного списка каждого пользователя с помощью *ILD*, и окончательная оценка *ILD* была рассчитана путем усреднения значений *ILD* для каждого списка пользователей. Полученные результаты приведены в таблице 1.

Таблица 1. Результат

	<i>ILD</i>	<i>RMSE</i>
<i>UserCF</i>	0.2336	1.1128
<i>ExpertRec</i>	0.2694	1.4737

Погрешность прогнозирования рейтинга, измеряемая в *RMSE*, показывает, насколько прогнозируемый рейтинг отклоняется от фактического рейтинга. Согласно результатам, эта ошибка больше в *ExpertRec* по сравнению с *UserCF*. Результаты также показывают, что оценка *ILD ExpertRec* больше, чем *UserCF*. Это указывает на то, что *ExpertRec* работает лучше, чем *UserCF* в отношении разнообразия.

Анализируя результаты, мы заметили, что *ExpertRec* не работает лучше, чем *UserCF* в задаче прогнозирования рейтинга. Поскольку *UScore* в *ExpertRec* рассчитывается по контент-ориентированному подходу, и единственным контентом, который мы рассматривали, был жанр в кино, вышеуказанное препятствие можно было бы уменьшить, если бы использовалось больше функций, поскольку *UScore* вносит значительный вклад в окончательный прогнозируемый рейтинг. Это также может быть связано с некоторыми ограничениями, присущими метрикам измерения точности.

Как и ожидалось, для разнообразия *ExpertRec* дал лучшие результаты. *UserCF* рекомендует фильмы, которые оценили соседи, имеющие схожий вкус с пользователем. Если соседи, которые имеют большое сходство с пользователем, выбраны, основываясь на транзитивном свойстве, каждый сосед будет похож друг на друга, потому что их предпочтения однородны. Таким образом, набор рекомендаций, выработанных из их предпочтений, будет однородным. Рекомендуя фильм пользователю, *ExpertRec* учитывает рейтинги, данные Экспертами соответствующего жанра, а не рейтинги соседей пользователя. Эти Эксперты могут иметь или не иметь сходство с предпочтениями пользователя. Мы рассматриваем их рейтинги, потому что считаем, что, поскольку они являются экспертами в определенном жанре, фильмы, которые они высоко оценили, на самом деле являются хорошими и полезными фильмами, и можно с уверенностью рекомендовать такой фильм пользователю. Мы должны отметить,

что мы рассматриваем, предпочитает ли пользователь фильмы этого жанра, а также $UScore$. Но фильм, который не имеет никакого сходства с прошлыми предпочтениями пользователя, имеет шанс быть рекомендованным в *ExpertRec*, если он высоко оценен экспертами. Таким образом, *ExpertRec* обладает врожденными качествами для продвижения разнообразия и подтверждается полученными результатами.

Эксперименты для *PersonalizedDiv*

Мы провели качественные и количественные эксперименты, чтобы проверить способность *PersonalizedDiv* диверсифицировать список рекомендаций персонализированным образом, контролируя при этом актуальность и разнообразие компромиссов.

Качественные эксперименты

Основной целью наших качественных экспериментов было убедиться, что процесс диверсификации *PersonalizedDiv* персонализирован. Таким образом, мы надеемся выяснить, способен ли *PersonalizedDiv* диверсифицировать список рекомендаций более новыми элементами, если пользователь в прошлом демонстрировал различные предпочтения, т.е. пользователь, который предпочитает исследовать новые вещи, и разнообразить список более релевантными элементами, если пользователь показывал однородные предпочтения в прошлом.

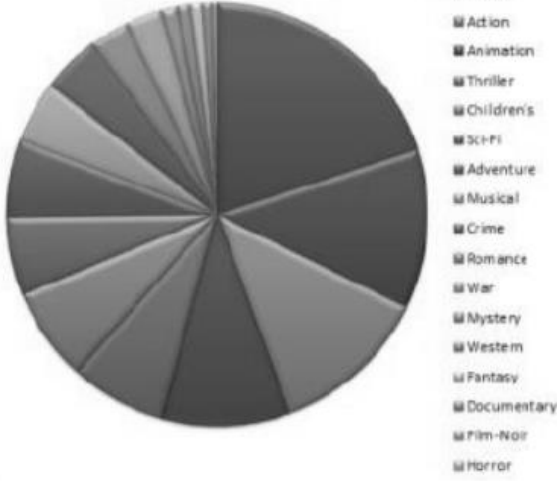
Сначала мы проанализировали набор данных и определили три уровня разнообразия, а затем случайным образом выбрали трех пользователей для трех уровней. Уровни:

- высокий уровень: $0.7 \leq D_u \leq 1.0$.
- средний уровень: $0.4 \leq D_u < 0.7$.
- низкий уровень: $0.0 \leq D_u < 0.4$.

Мы сгенерировали список элементов-кандидатов с помощью *ExpertRec* и окончательный список рекомендаций с помощью *PersonalizedDiv* для каждого из трех пользователей. Мы настроили $\lambda = 0$ в (7) для достижения максимального разнообразия для эксперимента над поведением диверсификации. Мы тщательно изучили сформированный окончательный список рекомендаций и сгенерирован C_u для проверки того, персонализирован ли процесс диверсификации.

Как показано в Таблице 2, вкусы пользователя разнообразны, и Мистерия, Вестерн, Фэнтези, Документальный и Фильм-Нуар — это жанры, в которых он имеет наименьший опыт, в то время как Ужасы являются самым новым жанром, поскольку его нет в C_u . Его список рекомендаций имеет больше предметы из вышеперечисленных жанров. Однако это невозможно, если новые элементы не присутствовали в списке элементов-кандидатов, созданном *ExpertRec*. *ExpertRec* учитывает прошлые предпочтения пользователя к жанрам, а также рейтинги, данные экспертами. Новые предметы ожидаются из-за рассмотрения оценок, данных экспертами. Поскольку ужасы — это жанр романа для этого пользователя, который не находится в его C_u , единственной перспективой добавления фильма ужасов в список кандидатов является *EScore* в (6), данный экспертами по ужасам рекомендуемым фильмам ужасов. Это свидетельствует о том, что рейтинги экспертов оказывают влияние на добавление новых пунктов в окончательный рекомендательный список.

Таблица 2. Рекомендации для пользователя (высокое разнообразие)

Профиль пользователя - <i>Высокий</i> уровень	Рекомендательный перечень
	<p>567 Ужасы</p> <p>770 Преступление Фильм-нуар Тайна Триллер</p> <p>217 Ужасы Романтика</p> <p>1004 Драма Вестерн 182</p> <p>Криминал Драма 860</p> <p>Ужасы Триллер 1472</p> <p>Комедия Научная фантастика</p> <p>951 Приключение Детские Фэнтези 835 Комедия Мюзикл Романтика 483 Драма Романтика Война</p>

Пользователь в Таблице 3 имеет однородные предпочтения, которые не очень разнообразны. Его основными интересами являются боевик и триллер, в то время как приключения, романтика и преступление являются его другими предпочтениями. Его список рекомендаций диверсифицирован с большим количеством элементов предпочтительных жанров пользователя, которые включают жанры, которые мы упомянули.

Таблица 3. Рекомендации для пользователя (низкое разнообразие)

Профиль пользователя - <i>Низкоуровневый</i>	Рекомендательный перечень
	<p>977 Акция</p> <p>273 Акция Преступность Триллер 925 Триллер</p> <p>1250 Акция</p> <p>1239 Акция Приключения Романтика 773 Триллер</p> <p>174 Акция Приключение</p> <p>33 Акция Романтика Триллер</p> <p>1139 Экшн Преступность Триллер 771 Экшн Научная фантастика Триллер</p>

Таким образом, проведенный качественный эксперимент показывает, что *PersonalizedDiv* способен разнообразить список рекомендаций персонализированным образом, адаптируя их, продвигая новые или актуальные предметы.

Количественные эксперименты

Для дальнейшей оценки *PersonalizedDiv* мы провели эксперименты с различными конфигурациями *PersonalizedDiv*. Для измерения релевантности

мы использовали метрику $nDCG@k$, в которой верхние результаты списка кандидатов представляли *ideal DCG*, и мы использовали метрику *ILD* для разнообразия, как и раньше. Мы использовали как *ExpertRec*, так и *UserCF* для создания списков элементов-кандидатов.

Мы сравнили *PersonalizedDiv* со следующими базовыми *иста-оф-арт* техниками.

1. Случайное разнообразие: случайный выбор k элементов из списка кандидатов.

2. Отсутствие разнообразия: выбор верхних k позиций из списка кандидатов

3. *MMR*[8] ($\lambda = 0.5$): Современный метод диверсификации, сконфигурированный для получения равного уровня разнообразия и актуальности. Сгенерированные списки кандидатов использовались в качестве входных данных для каждого из этих методов, а окончательные списки рекомендаций были сформированы для продолжения процесса оценки. Полученные результаты приведены в таблице 4.

Таблица 4.

		<i>ExpertRec</i>		<i>UserCF</i>	
		<i>ILD</i>	<i>nDCG</i>	<i>ILD</i>	<i>nDCG</i>
<i>MaxDiv</i>	Случайноеразнообразие	0.2654	-	0.2333	-
	ПерсонализированныйDiv $\lambda=0$	0.1965	-	0.0574	-
<i>MaxRel</i>	NoРазнообразие	-	1.000	-	1.000
	ПерсонализированныйIv $\lambda=1$	-	1.000	-	1.000

Согласно результатам *MaxDiv* в Таблице 4, более высокий балл разнообразия, чем *PersonalizedDiv* как для *ExpertRec*, так и для *UserCF*, получен случайным разнообразием. Поскольку рандомизация является источником

высшего разнообразия, для PersonalizedDiv практически невозможно получить более высокий или такой же уровень разнообразия при сохранении аспекта персонализации. Если мы сравним оценки разнообразия ExpertRec and UserCF, мы можем заметить, что существует замечательный контраст между оценками, и ExpertRec показывает более высокий показатель разнообразия. Причиной этого может быть более высокий балл разнообразия, полученный списком кандидатов ExpertRec, как в Таблице 1.

Результаты MaxRel в таблице IV указывают, как PersonalizedDiv и No Diversity получил максимальный балл релевантности 1,0 для списков кандидатов, сформированных как из ExpertRec, так и из UserCF. Поскольку и No Diversity, и PersonalizedDiv($\lambda=1$) (согласно (7)) возвращают верхние элементы списка кандидатов, а метрика nDCG также учитывает тот же набор элементов, что и идеально релевантный список элементов, ожидается, что оба получат максимальные результаты.

Результаты конфигурации Equal Diversity & Relevance приведены в таблице 5, где рассчитывается среднее значение разнообразия и релевантности. Согласно результатам, ExpertRec поддерживает как MMR, так и PersonalizedDiv для достижения более высоких результатов по сравнению с UserCF. Результаты также показывают, что, когда пользователь нуждается как в разнообразии, так и в релевантности, мы должны рассмотреть возможность создания списка кандидатов из ExpertRec и использовать метод постфильтрации MMR. Когда пользователь нуждается в разнообразии и релевантности наряду с персонализацией, мы должны рассмотреть возможность создания списка кандидатов из UserCF вместе с техникой PersonalizedDiv. Из результатов мы можем наблюдать, что мы достигли лучших результатов, чем неперсонализированная MMR, даже с дополнительным этапом персонализации, используя элементы-кандидаты, сгенерированные из UserCF.

Таблица 5. Объединенный результат для PersonalizedDiv

		ExpertRec	UserCF
		avg(ILD;nDCG)	avg(ILD;nDCG)
Equal Div & Rel	MMR $\lambda=0.5$	0.6223	0.5302
	ПерсонализированныйDiv $\lambda=0.5$	0.5583	0.5322

Из экспериментов мы также можем сделать вывод, что список кандидатов, сгенерированный ExpertRec, является абсолютным победителем для конфигураций MaxDiv и Equal Div&Rel для всех подходов после фильтрации и для MaxRel как для ExpertRec, так и для UserCF. являются победителями. При настройке на максимальное разнообразие PersonalizedDiv работает лучше с ExpertRec, что показывает, что подход ExpertRec положительно повлиял на PersonalizedDiv для достижения более высокого разнообразия даже с дополнительными этап персонализации.

Заключение

Предлагаемые подходы *ExpertRec* и *PersonalizedDiv* вместе демонстрируют способность персонализировать диверсификацию рекомендаций, позволяя контролировать компромисс между разнообразием и актуальностью, а также с учетом рейтингов экспертов. Результаты экспериментов показали, что подход обеспечивает сопоставимые результаты с современными подходами.

Библиографический список:

1. Burke R., Hybrid Recommender Systems: Survey and Experiments // User Modeling and User-Adapted Interaction 12(4). 2002. P. 331–370.
2. Sean J., McNee M., Konstan J. Accurate is not always good: How accuracy metrics have hurt recommender systems // Extended abstracts on Human factors in computing systems (CHI06). 2016. P. 1097–1101.
3. Barraza-Urbina A., Heitmann B., Hayes C., Carrillo-Ramos A. Xplodiv: An exploitation-exploration aware diversification approach for recommender systems //

The Twenty-Eighth International Flairs Conference. 2015. P.189-196.

4. Vargas S., Castells P. Exploiting the diversity of user preferences for recommendation // Proceedings of the 10th Conference on Open Research Areas in Information Retrieval. 2013. P.129-136.

5. Ziegler C.N., McNee S. M., Konstan J. A., Lausen G. Improving recommendation lists through topic diversification // 14th international conference on World Wide Web. ACM. 2005. P.22–32.

6. Smyth B., McClave P. Similarity vs. diversity // Case-Based Reasoning Research and Development. Springer. 2001. P.347–361.

7. Chen L., Wu W., He L. How personality influences users' needs for recommendation diversity? // CHI'13 Extended Abstracts on Human Factors in Computing Systems. ACM. 2013. P.829–834.

8. Carbonell J., Goldstein J. The use of mmr, diversity-based reranking for reordering documents and producing summaries // 21st annual international ACM SIGIR conference on Research and development in information retrieval. ACM. 1998. P.335–336.

9. Di Noia T., Ostuni V. C., Rosati J., Tomeo P., Di Sciascio E. An analysis of users' propensity toward diversity in recommendations // 8th ACM Conference on Recommender systems. ACM. 2014. P.285–288.