



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004

РАЗРАБОТКА РЕКОМЕНДАТЕЛЬНОЙ СИСТЕМЫ ФИЛЬМОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

¹Фофанов М.А., ²Горелов В.С., ³Сулиман А.А.

ФГБОУ ВО «Санкт-Петербургский государственный университет», Санкт-Петербург, Россия (199034, город Санкт-Петербург, Университетская наб., д.7/9), e-mail:

¹max.fofanov@gmail.com, ²vasylyigorelov@gmail.com, ³adamsulimanofficial@gmail.com

В работе рассматривается задача создания рекомендательной системы для фильмов. Мы предлагаем подход, основанный на эмбединге пользователей и фильмов. Для этого мы разработали уникальную архитектуру нейронной сети и обучили её на наборе данных с отзывами пользователей с портала IMDB. Результаты подтверждают потенциал использования нейронных сетей для улучшения персонализированной рекомендации фильмов.

Ключевые слова: Рекомендательная система; нейронная сеть; эмбединг.

DEVELOPMENT OF A MOVIE RECOMMENDER SYSTEM USING NEURAL NETWORKS

¹Fofanov M.A., ²Gorelov V.S., ³Suliman A.A.

"St. Petersburg State University", St. Petersburg, Russia (199034, St. Petersburg, Universitetskaya naberezhnaya, 7/9), e-mail: ¹max.fofanov@gmail.com, ²vasylyigorelov@gmail.com,

³adamsulimanofficial@gmail.com

The task of creating a movie recommender system is addressed. An approach based on embedding users and movies is proposed. To achieve this, a unique neural network architecture was developed and trained on a dataset consisting of user reviews from the IMDb portal. The results confirmed the potential of using neural networks to improve personalized movie recommendations.

Keywords: recommender system; neural network; embedding.

В последние годы, с появлением огромного количества фильмов на онлайн-платформах, пользователям труднее стал даваться поиск фильмов, соответствующих их вкусам и предпочтениям. Рекомендательные системы фильмов играют важную роль в решении этой проблемы, поскольку они направлены на предоставление персонализированных рекомендаций фильмов на основе предыдущих взаимодействий и предпочтений пользователей. Традиционные подходы к рекомендации основывались на коллаборативной фильтрации и методах, основанных на содержимом, но часто не удавалось учесть сложные предпочтения пользователей и давать точные рекомендации. В данной статье мы предлагаем

новый подход, использующий нейронные сети для улучшения точности персонализации рекомендаций фильмов.

Для обучения и оценки нашей рекомендательной системы мы использовали данные с портала IMDb. Первый набор данных содержал оценки пользователей для определенных фильмов. Эти оценки представляли собой числовые значения, отражающие предпочтения пользователей к каждому фильму. Оценки пользователей позволяли нам понять, какие фильмы были оценены положительно или отрицательно, и использовать эту информацию для предоставления рекомендаций на основе предпочтений пользователя.

Второй набор данных содержал информацию о фильмах, такую как жанр, год выпуска и рейтинг. Эти данные предоставляют контекстуальную информацию о каждом фильме, которая помогла нам лучше понять его особенности и свойства. Жанры фильмов давали представление о жанровом предпочтении пользователей, год выпуска позволял учитывать предпочтения к определенным временным периодам, а рейтинг служил мерой популярности и качества фильма.

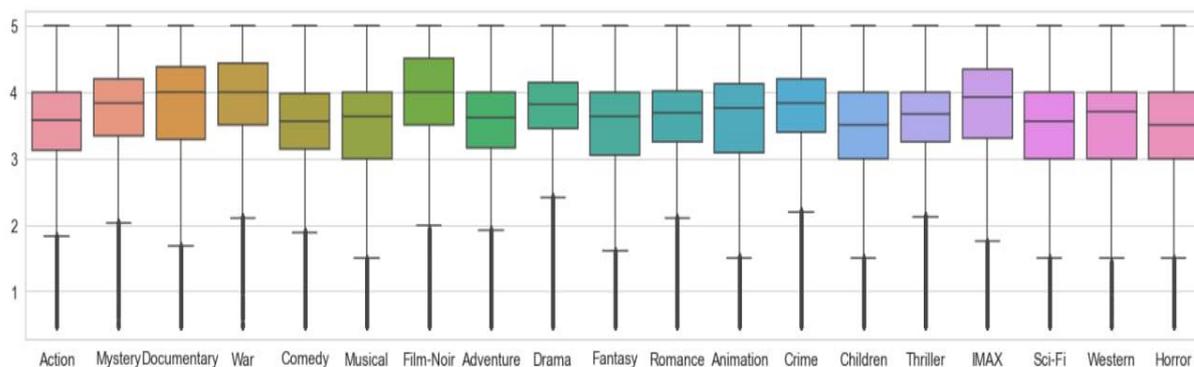


Рисунок 1 – Распределение средних оценок пользователей по жанрам

После проведения первичного анализа данных, мы обратили внимание на различия в восприятии жанров фильмов пользователями, основываясь на распределении средних оценок пользователей. Это отчетливо видно на Рисунке 1, где представлены графики распределения средних оценок пользователей для разных жанров фильмов. Наблюдается явное разделение жанров на те, которые получают высокие оценки пользователей, и те, которые оцениваются ниже. Эти результаты говорят о различных предпочтениях пользователей в отношении жанров фильмов и подтверждают важность учета таких факторов при разработке персонализированных рекомендаций фильмов.

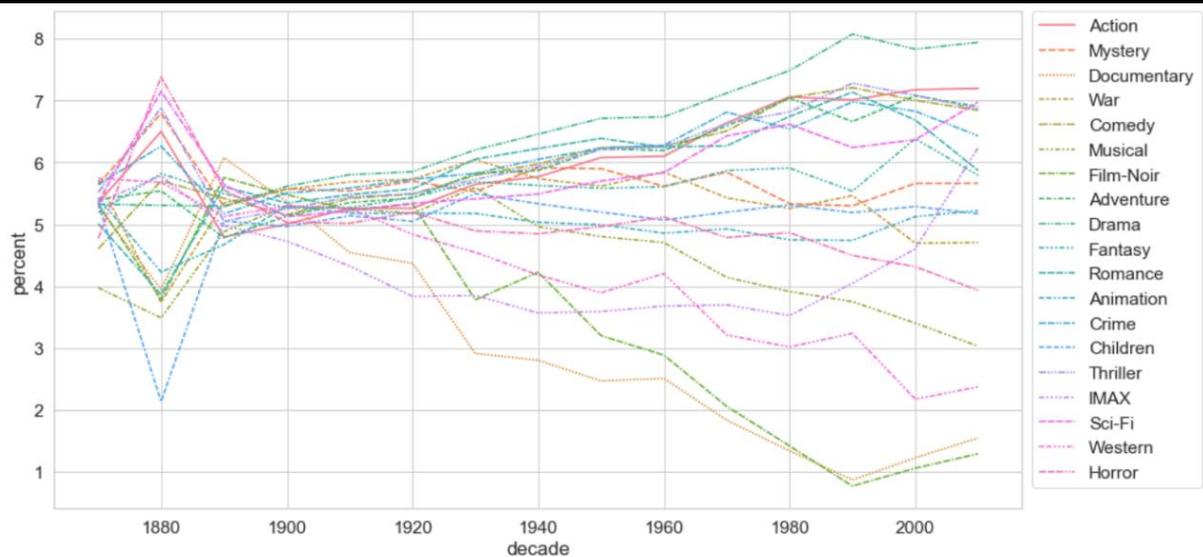


Рисунок 2 – Доля суммарных средних оценок пользователей по годам

В дополнение, мы провели анализ общей доли влияния жанров на всю киноиндустрию в каждом десятилетии. Интересно было выяснить, как год выпуска фильма влияет на предпочтения зрителей. Результаты этого анализа представлены на Рисунке 2, который изображает процентное разбиение жанровых предпочтений пользователей в зависимости от десятилетия выпуска фильма. Наблюдается значительное изменение предпочтений жанров с течением времени, отражая социокультурные изменения и тенденции в киноиндустрии. Эти выводы подчеркивают важность учета года выпуска при рекомендации фильмов, так как он существенно влияет на то, что люди склонны смотреть.

После предобработки и анализа данных мы перешли к этапу построения признаков. Для задачи эмбединга пользователей и фильмов наиболее подходящим решением представляется создание для них двух отдельных векторов признаков: профиль фильма и профиль пользователя. Профиль фильма — это вектор размерности $n+1$, где n — это количество уникальных жанров встречающихся в наборе данных. Каждой из первых n координат поставлен в соответствие какой-то жанр. Тогда первые n координат профиля выглядят следующим образом: на i -том месте стоит 1, если фильм относится к жанру соответствующему i -той координате, иначе 0. Стоит также отметить, что фильмы могут относиться к нескольким жанрам. Наконец, $n+1$ координата отведена под год выпуска фильма. Это необходимо, так как комедии 2000-х годов, например, сильно отличаются от комедий 1950-х.

Профиль пользователя — это вектор размерности $n+1$, где n — это количество уникальных жанров встречающихся в наборе данных. Каждой из первых n координат поставлен в соответствие такой же жанр, как и на этапе создания профилей фильмов. Тогда первые n координат выглядят следующим образом: на i -ом месте стоит средняя оценка пользователя для фильмов с жанром соответствующим i -ой координате или 0, если оценок для этого жанра нет. Наконец, $n+1$ координата отведена под любимый год пользователя, а именно год с наибольшей средней оценкой.

Архитектура нашей нейронной сети включает два блока: один для обработки профилей пользователей, а другой для обработки профилей фильмов. Каждый блок состоит из 4

полносвязных слоев с различными функциями активации, что позволяет модели извлекать и учитывать различные аспекты информации.

В первом блоке, профили пользователей подаются на вход и проходят через последовательность полносвязных слоев с активационной функцией гиперболического тангенса. Эти слои помогают выявить скрытые связи и особенности в профилях пользователей.

Аналогично, во втором блоке, профили фильмов подаются на вход и проходят через аналогичную последовательность полносвязных слоев с активационной функцией LeakyReLU. Эти слои позволяют нейросети изучать и кодировать характеристики фильмов, такие как жанры, год выпуска и рейтинг.

Затем, после обработки профилей пользователей и фильмов, мы рассчитываем косинусную метрику между двумя преобразованными векторами. Косинусная метрика измеряет сходство между двумя векторами и является показателем близости между предпочтениями пользователя и характеристиками фильма.

Наконец, результат косинусной метрики подвергается аффинным преобразованиям, чтобы привести его в промежуток от 0 до 5, чтобы его можно было сравнить с оценками пользователей. Это позволяет нам предоставить рекомендации с учетом пользовательских предпочтений и предсказать оценку фильма, которую пользователь мог бы дать.

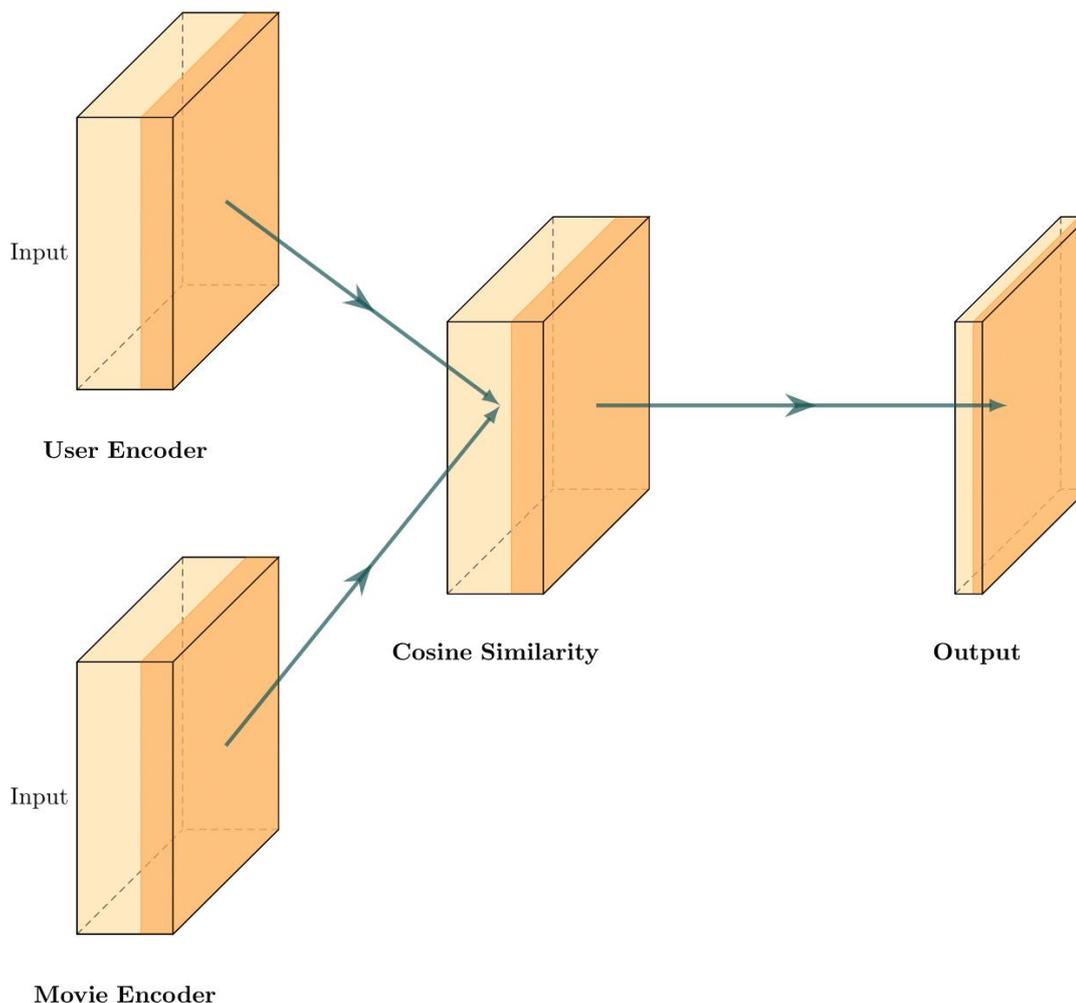


Рисунок 3 – Архитектура нейронной сети

Модель обучалась на задаче предсказания по профилю пользователя и профилю фильма оценки фильма у данного пользователя. В процессе обучения мы использовали различные методы для проверки корректности модели.

Во-первых, мы использовали валидационную выборку, которую модель не видела во время обучения, для отслеживания функции потерь. Это позволило нам оценивать производительность модели на новых данных и контролировать переобучение.

Во-вторых, мы применяли методы контроля скорости обучения. Когда процесс обучения достигал «плато», то есть когда функция потерь на валидационной выборке переставала значительно улучшаться, мы уменьшали скорость обучения. Это помогало предотвратить переобучение модели и повышало ее обобщающую способность.

По итогам обучения, наша модель продемонстрировала среднюю квадратичную ошибку на тестовой выборке, равную 0.78. Это говорит о том, что модель достаточно точно определяет, какие фильмы могут понравиться пользователю на основе их жанра и года производства. Полученные результаты свидетельствуют о высокой предсказательной способности модели и ее способности учесть предпочтения пользователей.

Кроме того, проведенный анализ с помощью метода ближайших соседей (knn) на полученных результатах подтверждает, что наша модель действительно научилась выделять фильмы, которые нравятся похожим пользователям, как более близкие. Это указывает на то, что модель способна улавливать схожие предпочтения между пользователями и рекомендовать фильмы, которые могут быть ими оценены положительно.

В целом, полученные результаты подтверждают эффективность и точность нашей модели в предсказании предпочтений пользователей и формировании персонализированных рекомендаций фильмов.

Для использования получившейся модели необходимо выделить часть использовавшуюся для кодирования фильмов и, используя её, получить латентные представления для фильмов. Затем, при необходимости получить выборку рекомендаций для пользователя, необходимо получить профиль пользователя, выделить часть использовавшуюся для кодирования зрителей и, применив её, найти первые n ближайших (по косинусной мере) латентных представлений фильмов с помощью одного из алгоритмов поиска ближайших соседей.

Тема рекламы и, в частности, персональных рекомендаций обретает особую актуальность в последние годы. Предложенная нами модель, не смотря на свою эффективность, проста и может быть улучшена сразу в нескольких направлениях. Во-первых, набор данных необходимо очистить от произведений, не являющихся полноценными фильмами, например отдельные серии сериалов, телевизионные шоу и слайд-шоу фильмы. Во-вторых, помимо жанра и года выпуска, у фильма есть достаточно много выделяющих его признаков: популярность фильма на различных ресурсах, страна выпуска (или язык оригинала), бюджет, длина, коммерческий успех, список людей причастных к созданию фильма. В-третьих, можно рассмотреть возможность расширения и модификации текущей архитектуры нейронной сети, чтобы улучшить её производительность и точность.

Список литературы

1. Cheng Guo, Felix Berkhahn. Entity embeddings of categorical variables// arXiv preprint arXiv:1604.06737. - 2016.
2. Xiangnan He, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu, Tat-Seng Chua// arXiv preprint arXiv:1708.05031. - 2017.
3. John Kalung Leung, Igor Griva, William G. Kennedy. Text-based emotion aware recommender// David C. Wyld et al. (Eds): CCSEA, BioT, DKMP, CLOUD, NLCAI, SIPRO - 2020 pp. 101-114.

References

1. Cheng Guo, Felix Berkhahn. Entity embeddings of categorical variables// arXiv preprint arXiv:1604.06737. - 2016.
2. Xiangnan He, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu, Tat-Seng Chua// arXiv preprint arXiv:1708.05031. - 2017.

Фофанов М.А., Горелов В.С., Сулиман А.А. Разработка рекомендательной системы фильмов с использованием нейронных сетей // Международный журнал информационных технологий и энергоэффективности. – 2023. – Т. 8 № 7(33) с. 16–22

3. John Kalung Leung, Igor Griva, William G. Kennedy. Text-based emotion aware recommender// David C. Wyld et al. (Eds): CCSEA, BIOT, DKMP, CLOUD, NLCAI, SIPRO - 2020 pp. 101-114.
-