

Uma Análise de Redes Sociais na Reprodução de Experimentos para o Desenvolvimento de Sistemas de Recomendação de Filmes na Netflix

Bruno F. Raquel¹, Ezequiel Park¹, Felipe M. Castro¹, Rodrigo D. Ferreira¹

¹Escola de Artes, Ciências e Humanidades – Universidade de São Paulo (USP)
São Paulo – SP – Brasil

brunofraquel@usp.br, ezequiel.park@usp.br,

felmateos@usp.br, rodrigodornelesferreira@usp.br

Abstract. *This article proposes an in-depth investigation into movie recommendation strategies on Netflix, specifically focusing on the analysis of social networks as a crucial element in reproducing experiments for the development of these systems. The research aims to understand how online social interactions influence users' viewing choices, particularly in the context of the streaming platform.*

Resumo. *Este artigo propõe uma investigação aprofundada sobre estratégias de recomendação de filmes na Netflix, focalizando especificamente na análise de redes sociais como um elemento crucial na reprodução de experimentos para o desenvolvimento desses sistemas. A pesquisa busca compreender como as interações sociais online influenciam as escolhas de visualização dos usuários, especialmente no contexto da plataforma de streaming.*

1. Introdução


“O objetivo é transformar dados em informação e informação em entendimento.” Com essa frase de Greg Peters CEO da Netflix, iniciamos a descrição de um problema muito comum para as empresas: a busca por dados precisos de seus usuários.

Redes Sociais, de uma forma geral, possuem um problema quanto a complexidade em entender os gostos dos usuários. Por conta desse motivo, durante o crescimento da Netflix, especialmente, durante a escalabilidade dos sistemas de recomendação, a empresa teve dificuldades em aprimorar e expandir seu sistema para antecipar as preferências dos usuários.

Desse fato temos uma questão: em uma natureza humana tão espontânea e subjetiva, como podemos interpretar seus desejos? É essa pergunta que o artigo busca responder.

1.1. Problema

Analisando esse tópico observa-se a presença de muitas variáveis discretas que definem uma determinada escolha de um indivíduo. Buscando uma forma de interpretar esta subjetividade humana a Netflix divulgou um prêmio que chamava a comunidade para quebrar essa barreira. A corrida para achar uma solução que melhorasse 10 por cento o Sistema



Leaderboard

Showing Test Score. [Click here to show quiz score](#)

Display top leaders.

Rank	Team Name	Best Test Score	% Improvement	Best Submit Time
Grand Prize - RMSE = 0.8567 - Winning Team: BellKor's Pragmatic Chaos				
1	BellKor's Pragmatic Chaos	0.8567	10.06	2009-07-26 18:18:28
2	The Ensemble	0.8567	10.06	2009-07-26 18:38:22
3	Grand Prize Team	0.8582	9.90	2009-07-10 21:24:40
4	Opera Solutions and Vandelay United	0.8588	9.84	2009-07-10 01:12:31
5	Vandelay Industries !	0.8591	9.81	2009-07-10 00:32:20
6	PragmaticTheorv	0.8594	9.77	2009-06-24 12:06:56
7	BellKor in BigChaos	0.8601	9.70	2009-05-13 08:14:09
8	Dace_	0.8612	9.59	2009-07-24 17:18:43

Figura 1. Página do Netflix Prize com os vencedores e Acurácia

de Recomendação já existente deles. Essa competição durou 3 anos (2006 até 2009) e contou com a participação de diversas equipes com soluções inovadoras.

A partir de leituras sobre referências no contexto de sistemas de recomendação definimos o tema **Explorando Estratégias de Recomendação: Uma Análise de Redes Sociais na Reprodução de Experimentos para o Desenvolvimento de Sistemas de Recomendação de Filmes na Netflix**.

1.2. Justificativa

A escolha deste estudo decorre da significativa relevância inerente ao tema abordado, mesmo que de maneira indireta. Os sistemas de recomendação representam a essência de uma experiência satisfatória para o usuário. Além disso, a obtenção de dados concretos sobre os clientes e sugestões relacionadas aos seus possíveis gostos confere à Netflix uma vantagem estratégica.

Considerando a centralidade desse aspecto na experiência do usuário, qualquer aprimoramento nesse âmbito resulta em uma melhoria substancial no relacionamento entre o usuário e a plataforma.

1.3. Objetivos

Os objetivos desta pesquisa consistem em replicar experimentos identificados na literatura, associando-os à análise de redes sociais. Além disso, almejamos, quando possível, buscar aprimoramentos para os algoritmos já propostos, visando contribuir para o avanço e refinamento dos sistemas de recomendação.

2. Conceitos Básicos

O desenvolvimento do nosso sistema de recomendação de filmes envolveu a aplicação de diversos conceitos fundamentais no campo de inteligência artificial. Neste trabalho, apresentamos uma breve descrição dos conceitos utilizados ao longo do trabalho, delineando como essas ferramentas e técnicas foram aplicadas para criar uma solução eficaz de filtro colaborativo.

2.1. Inteligência Artificial (IA)

A Inteligência Artificial (IA) é o alicerce que sustenta nosso sistema, capacitando-o a aprender padrões complexos e realizar previsões significativas. Neste contexto, a IA atua na compreensão das preferências dos usuários com base nas avaliações de filmes, aprimorando continuamente as recomendações.

2.2. Filtro Colaborativo

O Filtro Colaborativo é uma técnica de recomendação que se baseia na coleta e análise de preferências de um grupo de usuários. Utilizamos a abordagem de filtro colaborativo para calcular a similaridade entre usuários com base nas avaliações de filmes, permitindo prever e recomendar filmes ainda não assistidos.

2.3. Filtro baseado em Conteúdo

São filtros que analisam os atributos intrínsecos dos itens para criar perfis ou representações desses itens, permitindo recomendações baseadas na similaridade entre esses perfis e as preferências do usuário. Ele se concentra nas características intrínsecas dos itens (filmes, músicas, produtos etc.) e dos usuários para fazer recomendações em vez de depender das interações passadas entre usuários e itens.

2.4. Combinação desses elementos

O desenvolvimento do nosso sistema de recomendação envolveu a sinergia desses conceitos e ferramentas, criando uma solução que não apenas antecipa as preferências dos usuários, mas também proporciona uma experiência personalizada e eficaz na descoberta de filmes. Este trabalho representa não apenas uma aplicação prática de conceitos fundamentais, mas também um passo significativo em direção à melhoria contínua e à inovação no campo de sistemas de recomendação de filmes.

3. Revisão da Literatura

A literatura sobre sistemas de recomendações se divide basicamente em 3 grandes grupos de pesquisa de acordo com as técnicas de filtragem: filtragem colaborativa, filtragem baseada em conteúdo e filtragem híbrida. A filtragem colaborativa pode ainda ser dividida em baseada em usuário e baseadas em item (SARWAR, 2001) . As baseadas em usuário analisa as preferências de um usuário e encontra usuários semelhantes para oferecer recomendações com base nas escolhas desses usuários semelhantes. Já as baseada em Item: Analisa os itens em si e recomenda itens semelhantes aos que o usuário gostou no passado.

As técnicas de filtragem por conteúdo (LOPS, 2010) analisam as características dos itens (conteúdo) e sugere itens semelhantes aos que o usuário demonstrou interesse anteriormente. Usa informações como descrições, metadados ou atributos dos itens.

Os métodos híbridos (BURK, 2002) combinam elementos de filtragem colaborativa e filtragem por conteúdo para fornecer recomendações mais precisas e abrangentes. Podem ser integrados de várias maneiras, como usando sistemas separados e combinando suas saídas ou incorporando elementos de um método em outro.

Para os trabalhos correlatos deste trabalho, duas principais bibliografias foram utilizadas: “Recommender system techniques applied to Netflix movie data” e “The Big-Chaos Solution to the Netflix Grand Prize”. O trabalho “Recommender system techniques applied to Netflix movie data”, desenvolvida por Steven Postmus da Universidade Livre de Amsterdam em 2018, contém um conjunto de abordagens, metodologias e avaliações de diversas técnicas de sistemas de recomendação, que foram aplicadas às avaliações dadas aos filmes da Netflix no IMDB. O objetivo desse trabalho era recomendar filmes aos usuários que ainda não foram assistidos por eles.

Nesse trabalho, portanto, ocorre uma descrição e experimento com algumas possíveis técnicas utilizadas em cima dos dados para fazer uma boa recomendação: recomendação aleatória, filtragem colaborativa (baseado em item, usuários e decomposição em valores singulares), filtragem baseado em conteúdo e a filtragem híbrida. Nas avaliações de modelos, ao se utilizar a curva ROC, o que apresentou o melhor classificador foi a técnica de filtragem colaborativa por decomposição em valores singulares (Singular Vector Decomposition ou SVD).

No entanto, para obter resultados satisfatórios, um modelo híbrido é criado a partir do SVD e da filtragem baseada em conteúdo, que foi escolhido pelo ganho cumulativo com desconto normalizado (Normalized Discounted Cumulative Gain ou NDCG). No fim, após diversos testes de modelo, na análise desse trabalho, o que foi descoberto é que, para um bom modelo híbrido, os pesos de cada técnica deveriam ser, respectivamente, 0.6 e 0.4 para o SVD e a filtragem baseada em conteúdo.

Boa parte dos conceitos e técnicas utilizadas nesse artigo foram reaproveitados para implementação do sistema de recomendação deste trabalho de análise. No entanto, o foco foi a filtragem colaborativa com similaridade por cossenos.

4. Materiais e Métodos

4.1. Ferramentas Utilizadas

1. **Pandas e NumPy:** As bibliotecas Pandas e NumPy foram utilizadas para manipulação eficiente de grandes conjuntos de dados, proporcionando limpeza, organização e análise numérica dos dados.
2. **Scikit-learn (sklearn):** O Scikit-learn desempenhou um papel crucial no cálculo da similaridade entre usuários e na avaliação das previsões do sistema, utilizando a função de similaridade por cosseno.
3. **Streamlit:** A plataforma Streamlit foi escolhida para o desenvolvimento da interface web, proporcionando uma maneira fácil e eficiente de criar aplicativos interativos.
4. **GitHub:** O GitHub serviu como sistema de versionamento central e plataforma para publicação do projeto, permitindo colaboração eficiente e disponibilidade pública.

4.2. Pré-processamento de Dados

1. **Remoção de Filmes com Menos de 20 Avaliações:** Filmes com menos de 20 avaliações foram removidos para garantir a robustez do sistema, concentrando-se nos filmes mais populares.

2. **Enriquecimento de Dados com TMDb 5000 Dataset:** Dados do TMDb 5000 dataset foram incorporados para expandir as capacidades do sistema para um modelo híbrido.

4.3. Divisão do Conjunto de Avaliações

1. **Segmentação por Timestamp:** O conjunto de avaliações foi dividido com base no 'timestamp', utilizando uma parte para construir a matriz de similaridade de usuários e reservando outra parte para avaliar a qualidade das recomendações.
2. **Cálculo de Similaridade por Cosseno:** A similaridade entre usuários foi calculada utilizando a técnica de similaridade por cosseno da biblioteca `cosine_similarity` do Scikit-learn.
3. **Composição e Ajuste Pós-processamento das Avaliações:** A similaridade foi utilizada para compor as avaliações preditas, sendo crucial nesse processo. Após a predição, realizamos um pós-processamento para ajustar as avaliações ao modelo do conjunto de dados original, que utiliza avaliações de 0 a 5, com incrementos de 0.5 em 0.5.

4.4. Geração de Recomendações

As recomendações finais foram selecionadas com base nas avaliações preditas ajustadas após o pós-processamento. Os filmes recomendados foram aqueles que obtiveram as maiores avaliações previstas, proporcionando aos usuários sugestões personalizadas e alinhadas com seus gostos cinematográficos.

4.5. Avaliação de Resultados

A métrica escolhida para avaliar a eficácia do sistema foi o Root Mean Square Error (RMSE), proporcionando uma medida quantitativa da discrepância entre as avaliações previstas e as avaliações reais dos usuários.

5. Resultados

Na busca por estratégias eficazes de recomendação, realizamos uma busca abrangente centrada na utilização do erro quadrático médio para avaliar o desempenho de nosso modelo.

Na análise dos resultados, observamos que o modelo de recomendação apresentou um erro quadrático médio de 3,0086 ao comparar as notas previstas dos filmes com suas avaliações reais. Este valor elevado de erro quadrático médio indica uma significativa discrepância entre as previsões do modelo e as avaliações reais dos usuários.

Um erro quadrático médio elevado como esse sugere que as recomendações fornecidas pelo modelo estão, em média, distantes das preferências reais dos usuários. Em outras palavras, as notas previstas para os filmes não estão alinhadas de forma satisfatória com as avaliações efetivas dos usuários, comprometendo a capacidade do modelo de prever com precisão as preferências individuais.

Esse alto valor de erro quadrático médio pode resultar em recomendações imprecisas e insatisfatórias para os usuários, o que, por sua vez, compromete a utilidade e a eficácia do sistema de recomendação. Portanto, é crucial abordar e reduzir esse erro por

```
Avaliação dos resultados

def eval_ratings():
    test = user_movie_test.copy()

    real = []
    preds = []

    for user in test.columns:
        for movie, _ in test[user].items():
            if test.loc[movie, user] != 0 and len(n_recommendations[n_recommendations['movieId'] == movie]['pred_rating'].values) > 0:
                title = movies.loc[movie]['title']
                real_rating = test.loc[movie, user]
                pred_rating = n_recommendations[n_recommendations['movieId'] == movie]['pred_rating'].values[0]

                real.append(real_rating)
                preds.append(pred_rating)

                #print(f'{user:10} - {title:50} - true rating: {real_rating}, pred rating: {pred_rating}, DIFF:{abs(real_rating - pred_rating)}')

    MSE = np.square(np.subtract(real, preds)).mean()
    RMSE = math.sqrt(MSE)
    print("Root Mean Square Error:\n")
    print(RMSE)

[234] ✓ 0.0s Python

eval_ratings()
[235] ✓ 2.5s Python
... Root Mean Square Error:
3.6886445538929264
```

Figura 2. Avaliação de Resultados

meio de ajustes e melhorias no modelo, considerando diferentes abordagens e refinamentos nos algoritmos de recomendação.

Embora os resultados iniciais não tenham atingido a satisfação desejada, esses desafios nos incentivam a aprimorar nossas estratégias de recomendação, considerando ajustes nos filtros colaborativos e de conteúdo cada vez mais.

Para enriquecer a compreensão prática dos resultados apresentados, disponibilizamos uma plataforma interativa denominada EACHFLIX (<https://eachflix.streamlit.app/>). Essa plataforma visa fornecer uma demonstração concreta do sistema de recomendação discutido no estudo, permitindo que os usuários explorem a aplicação das estratégias de filtro colaborativo com similaridade por cosseno.

5.1. EACHFLIX em Ação

Ao acessar a plataforma, os usuários encontrarão uma interface simples e direta. O processo de utilização envolve os seguintes passos:

5.1.1. Seleção de Usuário

Na página inicial, é possível escolher um usuário entre os disponíveis na base de dados. Cada usuário representa diferentes preferências cinematográficas, proporcionando uma variedade de perfis para avaliação.

5.1.2. Geração de Recomendações

Após a seleção do usuário, basta clicar no botão "Gerar Recomendações". Nesse momento, o algoritmo de filtro colaborativo, baseado na similaridade por cosseno, entra em ação, analisando padrões de visualização semelhantes entre usuários e recomendando filmes que o usuário selecionado provavelmente apreciaria.



Figura 3. Selecionando Usuário para Gerar Recomendações

5.1.3. Exploração de Resultados

As recomendações geradas são apresentadas em uma lista organizada, fornecendo informações sobre cada filme, incluindo nome e a nota prevista. Os usuários podem explorar essas sugestões personalizadas, proporcionando uma visão prática das recomendações geradas pelo modelo.

5.2. Utilidade para Interpretação e Aprendizado

Ao utilizar a EACHFLIX, pode-se experimentar diretamente o funcionamento do sistema de recomendação. Essa aplicação prática facilita a compreensão das estratégias implementadas e permite uma experiência mais concreta contribuindo, assim sendo, para uma compreensão mais profunda do papel e dos desafios envolvidos na construção de sistemas de recomendação.

6. Conclusão

O desenvolvimento e aprimoramento de sistemas de recomendação representam uma área crucial na pesquisa de tecnologias de informação e interação usuário-computador. Neste estudo, concentramo-nos na análise de estratégias de recomendação de filmes na Netflix, com foco específico na aplicação de técnicas colaborativas e de conteúdo. No entanto, os resultados obtidos, expressos pelo elevado erro quadrático médio de 3,0086, revelam a presença de desafios substanciais que necessitam de atenção cuidadosa e ajustes na abordagem adotada.

A análise crítica dos resultados aponta para a complexidade inerente na captura precisa das preferências dos usuários. A utilização da similaridade por cosseno como me-

didada de proximidade entre usuários no filtro colaborativo revelou limitações, indicando a necessidade de explorar métricas alternativas ou técnicas colaborativas mais avançadas. Da mesma forma, o filtro de conteúdo, apesar de suas promissoras premissas, não conseguiu superar completamente as limitações do filtro colaborativo, destacando a dificuldade de prever escolhas baseadas em características específicas dos filmes.

A estratégia de combinação de ambas as abordagens, atribuindo pesos às listas de filmes não assistidos, mostrou-se promissora, indicando que uma integração holística pode ser benéfica na geração de recomendações personalizadas. No entanto, ajustes e refinamentos adicionais são necessários para otimizar essa combinação e melhorar a precisão do modelo.

O estudo não apenas revela desafios, mas também aponta para oportunidades de aprendizado. A pesquisa científica é um processo dinâmico, e os resultados insatisfatórios não representam uma barreira intransponível, mas sim um estímulo para futuras investigações e aprimoramentos no campo de sistemas de recomendação.

Referências

- [1] S. Postmus and S. Bhulai, *Recommender system techniques applied to Netflix movie data Research Paper Business Analytics*, Disponível em: <https://vu-business-analytics.github.io/internship-office/papers/paper-postmus.pdf>.
- [2] *TMDB 5000 Movie Dataset*, Disponível em: <https://www.kaggle.com/datasets/tmdb/tmdb-movie-metadata>.
- [3] *MovieLens*, Disponível em: <https://grouplens.org/datasets/movielens/>.

SARWAR, B. et al. Item-based collaborative filtering recommendation algorithms. Proceedings of the tenth international conference on World Wide Web - WWW '01, maio 2001.

LOPS, P.; DE GEMMIS, M.; SEMERARO, G. Content-based Recommender Systems: State of the Art and Trends. *Recommender Systems Handbook*, p. 73–105, 5 out. 2010.

BURKE, R. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, v. 12, n. 4, p. 331–370, 2002.