



**UNIVERSIDADE ESTADUAL DA PARAÍBA  
CENTRO DE CIÊNCIA EXATAS, SOCIAIS E APLICADAS  
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

**MATEUS DA CUNHA QUIRINO**

**APLICAÇÃO PRÁTICA DE UM SISTEMA DE RECOMENDAÇÃO UTILIZADO EM  
PLATAFORMAS DE STREAMING DE VÍDEOS**

**PATOS  
2022**

MATEUS DA CUNHA QUIRINO

**APLICAÇÃO PRÁTICA DE UM SISTEMA DE RECOMENDAÇÃO UTILIZADO EM  
PLATAFORMAS DE STREAMING DE VÍDEOS**

Trabalho de Conclusão de Curso apresentado ao Programa de Graduação em Ciência da Computação da Universidade Estadual da Paraíba, como requisito parcial à obtenção do título de Bacharel em Ciência da Computação.

**Área de concentração:** Aprendizagem de máquina; Sistemas de recomendação.

**Orientador:** Prof. Dra. Jannayna Domingues Barros Filgueira

**PATOS**

**2022**

É expressamente proibido a comercialização deste documento, tanto na forma impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que na reprodução figure a identificação do autor, título, instituição e ano do trabalho.

Q8a Quirino, Mateus da Cunha.

Aplicação prática de um sistema de recomendação utilizado em plataformas de streaming de vídeos [manuscrito] / Mateus da Cunha Quirino. - 2022.

41 p. : il. colorido.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Computação) - Universidade Estadual da Paraíba, Centro de Ciências Exatas e Sociais Aplicadas , 2022.

"Orientação : Profa. Dra. Jannayna Domingues Barros Filgueira , Coordenação do Curso de Computação - CCEA."

1. Sistemas de recomendação. 2. Plataforma de streaming de vídeos. 3. Métodos de filtragem de informação. I. Título

21. ed. CDD 005.3

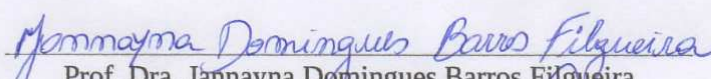
**Mateus da Cunha Quirino**

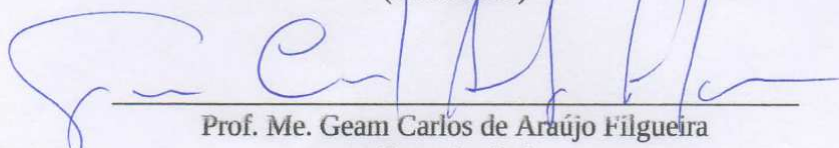
**APLICAÇÃO PRÁTICA DE UM SISTEMA DE RECOMENDAÇÃO UTILIZADO EM  
PLATAFORMAS DE STREAMING DE VÍDEOS**

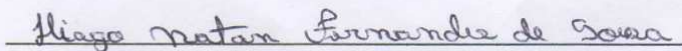
Trabalho de Conclusão de Curso apresentado ao Curso de Bacharelado em Ciência da Computação da Universidade Estadual da Paraíba, em cumprimento à exigência para obtenção do grau de Bacharel em Ciência da Computação.

Aprovado em 03/08/2022

**BANCA EXAMINADORA**

  
Prof. Dra. Jannayna Domingues Barros Filgueira  
(Orientador)

  
Prof. Me. Geam Carlos de Araújo Filgueira  
(Examinador)

  
Prof. Esp. Hiago Natan Fernandes de Sousa  
(Examinador)

Dedico o presente trabalho a minha mãe, a orientadora do trabalho, aos meus familiares, amigos e a todos aqueles que de certa forma contribuíram para a sua realização.

## **AGRADECIMENTOS**

A Deus por todos os dons a mim confiados, coragem, paciência e discernimento para superar todos os desafios.

A esta universidade, o corpo docente do curso que contribuiu para a construção do meu conhecimento e a todos os funcionários.

A minha orientadora Jannayna Domingues Barros Filgueira, por todos os ensinamentos diante das cadeiras ministradas, incentivo e suporte durante a construção deste trabalho.

A todos os meus familiares, em especial, a minha mãe Maria José da Cunha Quirino, por não medirem esforços para que eu não desistisse do curso incentivando no decorrer desta trajetória.

A todos os meus amigos e colegas de universidade, que compartilharam comigo os inúmeros momentos vividos e conhecimentos compartilhados ao longo da conclusão deste ciclo.

Aos voluntários que participaram desta pesquisa, possibilitando a conclusão deste trabalho.

E a todos que, direta ou indiretamente, contribuíram para a minha formação, o meu muitíssimo obrigado!

## RESUMO

Devido ao grande avanço dos sistemas de recomendações é possível perceber, cada vez mais, o quão poderosos eles podem ser no intuito de incitar o consumo. Diante disso, este trabalho visa demonstrar de forma prática a aplicação de algoritmos para filtragem colaborativa e filtragem baseada em conteúdo, utilizados em sistemas de recomendação, voltados a indicação de filmes. Para isso, foi desenvolvida uma aplicação simulando toda a usabilidade utilizada em plataformas de streaming de vídeos, a fim de capturar todas as interações dos usuários participantes do experimento. Através dos dados obtidos observou-se uma taxa de 76% (setenta e seis por cento) de aprovação, analisando todos os filmes recomendados a partir dos algoritmos de recomendação, como também que os filmes mais bem avaliados foram mais aceitos pelos usuários do sistema, explicitando a eficácia destes algoritmos em um ambiente que visa o consumo de algum produto ou serviço.

**Palavras-chave:** Sistemas de recomendação, Plataforma de streaming de vídeos, Métodos de filtragem de informação.

## **ABSTRACT**

Due to the great advance of recommendation systems, it is possible to perceive, more and more, how powerful they can be in order to incite consumption. Therefore, this work aims to demonstrate in a practical way the application of algorithms for collaborative filtering and content-based filtering, used in recommendation systems, aimed at movie indication. For this, an application was developed simulating all the usability used in video streaming platforms, in order to capture all the interactions of the users participating in the experiment. Through the data obtained, it was observed a rate of 76% (seventy-six percent) of approval, analyzing all the recommended films from the recommendation algorithms, as well as that the best evaluated films were more accepted by the users of the system, explaining the effectiveness of these algorithms in an environment that aims to consume some product or service.

**Keywords:** Recommender systems, Video streaming platform, Information filtering methods.



## LISTA DE ILUSTRAÇÕES

Figura 1:	Étapas de um sistema de recomendação.....	14
Figura 2:	Exemplo da filtragem colaborativa.....	16
Figura 3:	Exemplo da filtragem baseada em conteúdo.....	17
Figura 4:	Fórmula do coeficiente de correlação de Pearson.....	18
Figura 5:	Tipos de correlações utilizadas em Pearson.....	18
Figura 6:	Arquitetura de um sistema de recomendação.....	20
Figura 7:	Dados de um filme, em formato JSON.....	24
Figura 8:	Dados de uma interação, em formato JSON.....	25
Figura 9:	Objeto de interações de um usuário.....	25
Figura 10:	Objeto de interações de um usuário e filmes interagidos.....	26
Figura 11:	Representação da matriz de usuários e filmes.....	26
Figura 12:	Interações de um usuário de acordo com os gêneros.....	27
Figura 13:	Página de identificação do participante da pesquisa.....	30
Figura 14:	Usabilidade de inserção do nome.....	30
Figura 15:	Página inicial.....	31
Figura 16:	Notificação informando o objetivo da página inicial.....	31
Figura 17:	Carrossel com os cinco filmes mais populares.....	32
Figura 18:	Carrossel com filmes categorizados por gênero.....	32
Figura 19:	Usabilidade de visualização do nome de um filme.....	33
Figura 20:	Modal com informações de um filme.....	33
Figura 21:	Progresso de avaliação de filmes.....	34
Figura 22:	Cartão de um filme após ser avaliado.....	34
Figura 23:	Notificação informando o encerramento da primeira etapa.....	35
Figura 24:	Notificação informando o objetivo da página de recomendações.....	35
Figura 25:	Página de recomendações.....	35
Figura 26:	Modal com informações de um filme, na página de recomendações..	36
Figura 27:	Página final.....	36
Figura 28:	Filmes mais recomendados aos usuários.....	38

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>9</b>
<b>1.1</b>	<b>Objetivos.....</b>	<b>9</b>
1.1.1	Objetivo geral.....	9
1.1.2	Objetivos específicos.....	10
<b>1.2</b>	<b>Justificativa.....</b>	<b>10</b>
<b>1.3</b>	<b>Organização do trabalho.....</b>	<b>10</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA.....</b>	<b>12</b>
<b>2.1</b>	<b>Sistema de recomendação.....</b>	<b>12</b>
2.1.1	Etapas de um sistema de recomendação.....	14
2.1.2	Filtragem colaborativa.....	15
2.1.3	Filtragem baseada em conteúdo.....	17
2.1.4	Coeficiente de correlação de Pearson.....	18
2.1.5	Aplicações e objetivos.....	19
<b>2.2</b>	<b>Arquitetura de um sistema de recomendação.....</b>	<b>19</b>
<b>3</b>	<b>METODOLOGIA.....</b>	<b>21</b>
<b>3.1</b>	<b>Arquitetura da aplicação.....</b>	<b>21</b>
3.1.1	Aplicação backend.....	21
3.1.2	Aplicação frontend.....	23
<b>3.2</b>	<b>Processo de recomendação.....</b>	<b>23</b>
3.2.1	Tratamento dos dados.....	24
3.2.2	Aplicando a filtragem colaborativa.....	25
3.2.3	Aplicando a filtragem baseada em conteúdo.....	27
<b>4</b>	<b>APLICAÇÃO.....</b>	<b>29</b>
4.1	Página de identificação.....	29
4.2	Página inicial.....	31
4.3	Página de recomendações.....	35
4.4	Página final.....	36
<b>5</b>	<b>RESULTADOS.....</b>	<b>38</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS.....</b>	<b>39</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>40</b>

## 1. INTRODUÇÃO

Enfrentar a exponencialidade do crescimento de informações, tornou-se um desafio para as grandes empresas, como também, a necessidade de assertividade na exibição de seus conteúdos para os seus consumidores. Justamente porque diante do advento das mídias sociais teve-se de pensar em alternativas que pudessem filtrar as informações a partir de uma grande base de dados. Essa é a função dos sistemas de recomendação, otimizar o processo de busca na escolha dos conteúdos mais relevantes, ocasionando em ganhos reais trazendo uma melhoria significativa no desempenho do site e conseqüentemente vendendo mais, como também, possibilitando economia de tempo para as pessoas na busca de produtos desejados.

Visando acolher a necessidade de alcançar resultados adequados às expectativas dos usuários e abrandar o chamado *information overload* (conceito e definição utilizado para definir um estado de sobrecarga de informação), foram idealizados os “sistemas de recomendação”, a fim de capturar as informações mais relevantes com base nas características específicas de um conteúdo e no perfil dos usuários contribuintes de tais sistemas.

### 1.1 Objetivos

#### 1.1.1 Objetivo geral

O objetivo deste trabalho é demonstrar de forma prática a eficácia de algoritmos utilizados em sistemas de recomendação. Para que isso ocorra, se fez necessária a implementação de uma aplicação web com intuito de simular toda a usabilidade utilizada em plataformas de streaming de vídeo para captação de interações para alimentar e aplicar algoritmos de filtragem.

### 1.1.2 Objetivos específicos

- Realizar revisão bibliográfica sobre Sistemas de recomendação e os algoritmos utilizados;
- Demonstrar a implementação dos métodos de filtragem, utilizando as tecnologias mais utilizadas no mercado;
- Demonstrar a Implementação de uma plataforma para indicação de filmes, de modo a validar o sistema de recomendação;
- Analisar os resultados obtidos com a solução.

## 1.2 Justificativa

É perceptível o grande avanço das informações, como também, a falta de conhecimento acerca de sistemas de recomendação e o quão poderosos e eficientes eles são na busca de alcançar um maior consumo de conteúdos relevantes.

Analisando e levando em consideração tais premissas, com a elaboração desta pesquisa, poderá compreender melhor sobre tais conceitos, bem como suas aplicações de forma prática e objetiva, contribuindo como fonte de conhecimento para futuros projetos relacionados ao tema.

## 1.3 Organização do Trabalho

O trabalho está organizado da seguinte forma. Na seção 2 são introduzidos conceitos pertinentes aos temas abordados ao longo deste trabalho, tais como métodos de filtragem de informações e funções utilizadas na identificação do grau de similaridade entre usuários e itens.

A seção 3 aborda a metodologia utilizada durante toda a pesquisa, detalhando a arquitetura, organização, tecnologias e processos necessários para a conclusão deste projeto.

A seção 4 é abordado como foi desenvolvida a aplicação e a validação do sistema de recomendação.

A seção 5 apresenta as análises realizadas, juntamente com os resultados obtidos a partir das interações dos usuários participantes do experimento.

E, por fim, a seção 6 apresenta a conclusão do estudo, explicitando as considerações finais.

## **2. FUNDAMENTAÇÃO TEÓRICA**

Nesta seção será apresentada a fundamentação teórica deste trabalho, passando por cada um dos conceitos estudados, necessários para a realização desta pesquisa.

### **2.1 Sistema de recomendação**

Sistemas de Recomendação (SR), são softwares nos quais implementa-se uma ou mais técnicas que são capazes de sugerir itens para os usuários (RICCI, 2011).

Os Sistemas de Recomendação são ferramentas capazes de identificar preferências e sugerir itens relevantes para cada usuário, de acordo com a análise de seu comportamento de navegação, consulta e/ou compra, preferências, entre outros aspectos (REATEGUI, 2010).

Sistemas de Recomendação (SR), são softwares nos quais implementa-se uma ou mais técnicas que são capazes de sugerir itens para os usuários (RICCI, 2011). Esses itens recomendados podem ser dos mais variados tipos como filmes, músicas, produtos em lojas de comércio eletrônico, etc.

Dentre as empresas beneficiárias, que utilizam de sistemas de recomendação extremamente eficientes e que são bastante conhecidas, podemos destacar a Netflix e Amazon, que crescem cada dia mais e se assemelham no objetivo de ordenar e expor conteúdos de grande relevância e que venham a serem consumidos pelos seus usuários. Nisto, os sistemas de recomendações surgem como uma ferramenta hábil para filtragem e personalização dos conteúdos ofertados.

A Netflix possui uma enorme base de dados e para que seja possível um bom uso desses dados utilizam de sistemas de recomendações poderosos e eficientes. Cada conteúdo assistido e avaliado pelo usuário é utilizado como base para as próximas recomendações fazendo com que o que é assistido no site provenha das recomendações ao invés da busca, ocasionando em uma grande economia de tempo e satisfação de seus usuários.

A Amazon possui um dos sistemas de recomendação mais eficientes e de mais alta conversão. O site da Amazon utiliza as recomendações como ferramenta de marketing aplicando em seções como “Recomendados para você”, produtos que são comprados em conjunto frequentemente, inspirados no histórico de navegação, entre outras diversas formas de utilização das recomendações. Além disso, o site é totalmente personalizado de acordo com o cliente, ao passo que conforme se navega e há a ocorrência de interações, os produtos exibidos se alteram.

Em um mundo cheio de informações, que aumentam em uma enorme escala, graças ao grande avanço das tecnologias de informação, é desafiador encontrar informações que nos levem a decisões mais incisivas acerca daquilo que procuramos, com isso, os sistemas de recomendação nos são apresentados como facilitadores para filtragem de informações.

Até o século passado, o ouro era considerado como um dos bens mais valiosos do mundo, hoje em dia conseguimos afirmar que o real tesouro está nos nossos dados.

Nossos dados transitam por toda a web e são coletados e analisados constantemente a cada clique que damos em um vídeo, ou textos que lemos, em cada produto que colocamos em uma cesta de compras de uma loja virtual e a cada compartilhamento de imagem que fazemos para nossos amigos. Atualmente, toda interação que temos com uma página web qualquer, ou aplicativo de smartphone é transformado em informações, e para as empresas que comercializam algum tipo de produto ou serviço, elas valem ouro.

Até meados da década de 90, os SR não tinham grandes holofotes da comunidade científica, bem como não havia o reconhecimento como uma área de pesquisa independente, desde então a área vem crescendo exponencialmente e tomando grande parte dos setores de comercialização de produtos ou serviços (PAGNOSSIM, 2018).

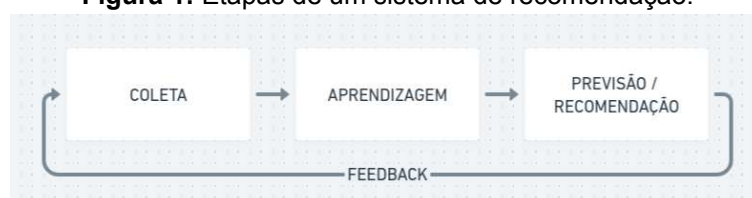
Usuários que se utilizam de informações sugeridas por tais sistemas são beneficiados das recomendações, ao passo que colaboram para o aperfeiçoamento e aprendizagem de tais ferramentas, que analisam cada interação e as registram a fim de melhorar as recomendações futuras.

Hoje em dia, os sistemas de recomendações são indispensáveis para as grandes empresas que possuem bases de dados enormes e que precisam de ferramentas eficazes na filtragem desses dados, para disponibilizar a melhor usabilidade possível a seus clientes na exibição de conteúdos personalizados a fim da obtenção de uma maior porcentagem de lucro. Segundo MacKenzie, Meyer e Noble (2013), 35% do que os consumidores compram na Amazon são influenciados por recomendações e 75% do que os assinantes assistem na Netflix vêm de recomendações. Registrando um aumento de vendas de 29% durante o segundo trimestre de 2011, a Amazon teve um aumento em relação ao ano anterior de \$9,9 bilhões para \$12,83 bilhões (MANGALINDAN, 2012).

### 2.1.1 Etapas de um sistema de recomendação

Segundo Isinkaye, Folajimi, Ojokoh (2015) e Kumar e Kumar (2019), os sistemas de recomendações constituem-se de três etapas principais, sendo a primeira a de coleta de informações, a segunda a etapa de aprendizagem e, a terceira, a de previsão e recomendação.

**Figura 1:** Etapas de um sistema de recomendação.



**Fonte:** Adaptado de Kumar e Kumar (2019).

Na primeira etapa, a de coleta, o sistema tem a missão de coletar todas as informações relevantes do usuário por meio de *feedbacks* implícitos, explícitos e híbridos.

- *Feedback* implícito: O sistema coleta as informações a partir do monitoramento de interações do usuário com a plataforma, analisando histórico, botões clicados, tempo de visualização dos conteúdos, entre outros.
- *Feedback* explícito: O usuário é solicitado a fornecer sua avaliação sobre determinados itens/produtos.



- *Feedback* híbrido: Em busca de um melhor desempenho, é utilizado o *feedback* implícito e o *feedback* explícito em conjunto.

Na segunda etapa, o sistema por meio de algoritmos de aprendizagem, busca entender as preferências do usuário a partir das informações coletadas na etapa de coleta.

E na terceira e última etapa, é recomendado itens que o usuário possa se interessar a partir dos padrões fornecidos pela fase de aprendizado.

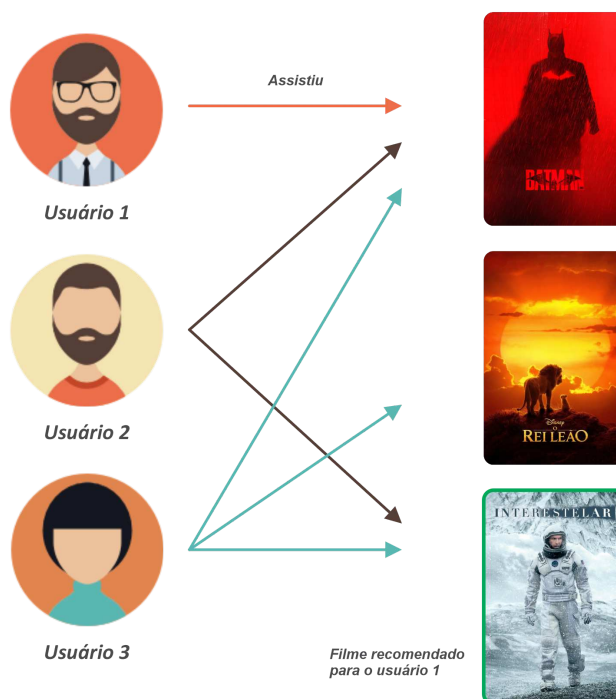
### 2.1.2 Filtragem colaborativa

Brunialti (2015) define que a filtragem colaborativa permite recomendar ao usuário atual, os itens que outros usuários similares a ele gostaram no passado. Resumidamente, é uma técnica baseada no conhecimento coletivo, através das opiniões e interações dos outros usuários o sistema identifica aqueles que possuem um maior grau de similaridade e realiza as recomendações que mais se encaixam no perfil do usuário.

Para isso, a filtragem colaborativa baseia-se nas escolhas que um usuário faz ao assistir, comprar, curtir, compartilhar alguma coisa. Logo depois, são feitas conexões com outros usuários de mesmos interesses, chegando a uma previsão do que recomendar.

Exemplificando, na netflix, o site e aplicativo são guiados pelas interações dos usuários, gerando uma enorme base de dados, no qual é utilizada para a realização de recomendações. A netflix ordena essas recomendações de tal forma que os filmes e séries melhores ranqueados sejam exibidos em primeiro, melhorando a usabilidade da plataforma, tendo em vista a satisfação do cliente ao visualizar o que seja de seu interesse em consumir.

**Figura 2:** Exemplo da filtragem colaborativa.



**Fonte:** Adaptado de Kumar e Kumar (2019).

Como podemos observar na figura 2, o usuário 1 assistiu o filme *The Batman* assim como os outros dois usuários, o algoritmo baseado em filtragem colaborativa analisará os filmes assistidos pelos os outros usuários, recomendando assim um filme que o usuário 1 ainda não assistiu e que possui as melhores avaliações, no caso, *Interestelar*.

Após realizarmos o cálculo de similaridade entre os usuários, selecionamos os vizinhos mais próximos realizando uma análise comparativa entre os itens consumidos por eles.

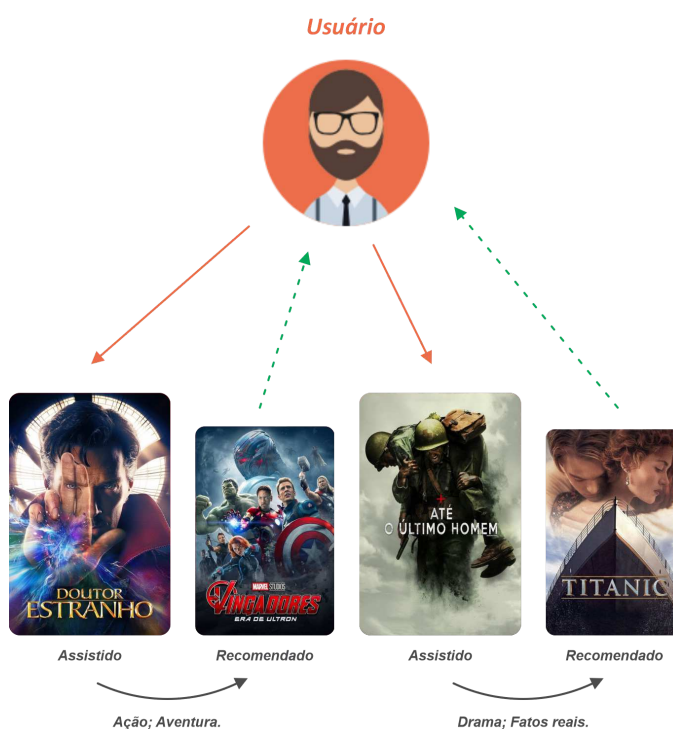
E por fim, é realizada a previsão para o usuário alvo de um item ainda não consumido, nesse cálculo será analisado o quão relevante será o item para o usuário alvo.

### 2.1.3 Filtragem baseada em conteúdo

Sistemas deste tipo, são fundamentados nas características dos produtos consumidos ou melhor avaliados pelo usuário. O modelo é capaz de prever e recomendar os melhores itens a partir das interações que o cliente realizou com outros itens que possuem alguma similaridade com o item em questão.

Segundo Motta et al. (2012), esta técnica baseia-se nas informações sobre o item em si, usando de algoritmos de aprendizagem de máquina a fim de organizar um perfil de preferências de um usuário a partir da similaridade entre os itens.

**Figura 3:** Exemplo da filtragem baseada em conteúdo.



**Fonte:** Elaborado pelo autor (2022).

Como podemos observar na figura 3, a partir dos itens avaliados pelo usuário e após criado um perfil de preferências do mesmo é recomendado itens que possuem o mesmo perfil.

Esta técnica é composta de 4 passos: Classificação dos itens avaliados segundo suas categorias; Cálculo da avaliação média de cada avaliador para cada

categoria; Ordenação dos itens avaliados, obtendo uma lista de preferências; Cálculo da previsão de avaliação (Motta et al., 2012).

Esta técnica possui diversas vantagens, como por exemplo, a ausência da necessidade de outros usuários, a capacidade de recomendação de itens não tão populares ou recém inseridos a base de dados, entre outras.

#### 2.1.4 Coeficiente de correlação de Pearson

Para a implementação da filtragem colaborativa primeiro é necessário realizar o cálculo da similaridade entre os usuários, assim como, para implementação da filtragem baseada em conteúdo é preciso verificar a similaridade dos itens. Nesta etapa verificamos, a partir das interações dos usuários com os determinados itens, o grau de similaridade entre os usuários. Sendo possível utilizar técnicas de correlação como por exemplo, a de Pearson (Coeficiente de Pearson).

**Figura 4:** Fórmula do coeficiente de correlação de Pearson.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{(\sum (x_i - \bar{x})^2)(\sum (y_i - \bar{y})^2)}}$$

**Fonte:** MEDSTATWEB (2017).

Também chamado de correlação linear, a correlação de Pearson, procura entender como duas variáveis se comportam, identificando o grau de similaridade através de valores situados entre -1 e 1, onde próximo ao -1 implicando a uma correlação negativa, ao 1 uma correlação positiva e próximo ao 0, nenhuma similaridade (Figura 3).

**Figura 5:** Tipos de correlações utilizadas em Pearson



**Fonte:** Elaborado pelo autor (2022).

### 2.1.5 Aplicações e objetivos

Os sistemas de recomendação podem ser aplicados nas mais diversas áreas, nos mais distintos segmentos. Onde houver algo que seja consumível, eles conseguirão auxiliar numa rápida e eficaz escolha do que for do interesse do usuário.

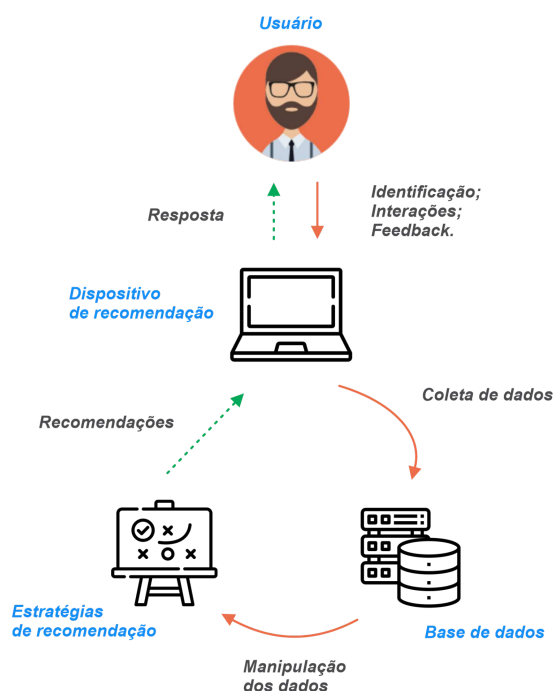
Para leitores, os sistemas recomendam os melhores livros, os mais bem conceituados artigos e notícias. Para varejistas e consumidores os melhores produtos, de acordo com as peculiaridades e especificidades de cada um. E para os amantes do cinema, dos streamings, os sistemas de recomendação os auxiliam na escolha do que assistir.

Os principais objetivos de tais sistemas são a fidelidade do usuário e obtenção de lucro, “a melhor maneira de avaliar a efetividade de um sistema de recomendação é entender se os itens recomendados são eventualmente consumidos.” (JARDIM, 2020).

## 2.2 Arquitetura de um Sistema de recomendação

A Figura 6, ilustra a arquitetura de um modelo de Sistema de Recomendação, onde ao coletar e armazenar os dados do usuário são aplicadas estratégias de recomendação personalizadas.

**Figura 6:** Arquitetura de um sistema de recomendação.



**Fonte:** Elaborado pelo autor (2022).

Inicialmente é realizada a identificação do usuário. Logo após, os dados do usuário são coletados e armazenados em uma base de dados. Após a coleta e armazenamento, são realizadas uma série de manipulações nos dados coletados a fim de aplicar as estratégias de recomendação que foram definidas pelo projetista do sistema. As recomendações criadas são enviadas ao usuário por dispositivos, o usuário interage com essas recomendações e o ciclo se reinicia.

### 3. METODOLOGIA

Realizando uma pesquisa qualitativa, tendo em vista a análise da eficácia dos algoritmos de recomendação, foi implementada uma aplicação simulando toda a usabilidade de uma plataforma de streaming de vídeos, sendo possível capturar todas as interações com os filmes avaliados pelos participantes da pesquisa, e logo após isso, foi possível realizar a recomendação de acordo com as escolhas do usuário, como também a obtenção das avaliações para os filmes recomendados.

A aplicação pode ser acessada, hospedada na plataforma da Vercel, pelo link “<https://acunha-plus.vercel.app/>” e o código fonte pelo link “<https://github.com/mateuscnh/acunha-plus>”.

#### 3.1 Arquitetura da aplicação

Respeitando as boas práticas de desenvolvimento de software, ao passo que, transformando a aplicação em um sistema escalável e de fácil manutenção, foi necessário dividi-la em duas aplicações, uma aplicação *backend* que gerenciou o servidor e é responsável pela manipulação dos dados, e uma aplicação *frontend*, que se responsabilizou por interagir diretamente com o usuário.

##### 3.1.1 Aplicação backend

A aplicação *backend* foi desenvolvida utilizando um ambiente de execução da linguagem de programação *Javascript*, linguagem padrão para manipulação de páginas *HTML*. O ambiente em questão foi o *Node.js*, utilizado por grandes empresas como Netflix, Uber, LinkedIn e PayPal.

Baseado em convenções utilizadas pela comunidade *Javascript*, a aplicação *backend* foi organizada de modo a facilitar a manutenção, bem como, otimizar o processo de compilação e interpretação da linguagem.

As informações dos filmes foram adquiridas a partir de uma base de dados gratuita e de código aberto, criado por *Travis Bell* em 2008, a *The Movie Database*, mais conhecida pela sigla *TMDb*.

Para a persistência dos dados, foi utilizado o sistema gerenciador de banco de dados *PostgreSQL*, devido a sua grande escalabilidade.

Foram criadas 5 tabelas:

1. “users”, para salvar os dados de todos os usuários da aplicação, contendo o nome e o número de identificação (id).
2. “movies”, para persistir os dados de todos os filmes, contendo os dados informados na Figura 21.
3. “genres”, para persistência de todos os gêneros dos filmes, contendo nome e número de identificação (id).
4. “interactions”, para guardar todas as interações dos usuários com filmes na primeira etapa da pesquisa, contendo os dados informados na Figura 22.
5. “interactions\_recommendations”, para persistir todos as interações de usuários com filmes recomendados.

Para realizar as consultas ao banco de dados SQL foi utilizado o *Knex*, um *query builder (Construtor de Consulta) poderoso*, utilizado em aplicações *Node.js*, que por meio do Javascript unifica a forma de realizar queries (*Consultas*), como também, aplicando os conceitos de *migrations* e *seeds*, permite aos desenvolvedores a inicialização, destruição e recriação do banco de dados rapidamente, minimizando assim problemas de inconsistência de dados, que possam vir a ocorrer.

A aplicação foi exposta como *API (Application Programming Interface)*, que consiste em “um conjunto de normas que possibilita a comunicação entre plataformas através de uma série de padrões e protocolos.” (FABRO, 2020).

A *API* foi desenvolvida em uma arquitetura *REST (Representational State Transfer)*, transportando dados no formato *JSON (JavaScript Object Notation)*.

Para o *deploy (Implantação)* de toda a aplicação *backend*, desde o servidor ao gerenciador de banco de dados, foi escolhida a plataforma de nuvem *Heroku*, que está em desenvolvimento desde 2007 e dá suporte a várias linguagens de programação.



### 3.1.2 Aplicação frontend

Antes da implementação da aplicação em si, foi realizado o desenvolvimento de um protótipo de alta fidelidade no *Figma*, uma das ferramentas mais utilizadas para prototipagem de interfaces gráficas. Foi pensada baseando-se nos princípios fundamentais do design de interação, para se obter uma experiência da melhor forma possível.

A aplicação *frontend* foi desenvolvida em *Javascript*, utilizando a biblioteca para criação de interfaces de usuário *React JS*. Criada e mantida pelo time do *Facebook*, em 2011, o *React* é uma das mais utilizadas bibliotecas de *Javascript* do mercado.

Pensando em otimizar e trazer uma melhor experiência para o usuário, foi utilizada a biblioteca para busca e cacheamento de dados *SWR*, mantida pela empresa *Vercel*, trazendo uma flexibilidade nas requisições as cacheando e as validando constantemente, tendo em vista a capacidade de se conseguir navegar por toda a plataforma sem precisar recarregar a todo momento.

Para a estilização, foi utilizada a biblioteca *Styled-components*, unida a biblioteca de componentes *Ant Design*, que possuindo uma diversidade de componentes prontos, possibilitou uma versatilidade e rapidez no desenvolvimento das interfaces.

Para o deploy da aplicação, foi utilizada a plataforma para sites estáticos e *frameworks frontend*, *Vercel*.

## 3.2 Processo de recomendação

Após o usuário realizar a avaliação dos filmes assistidos, antes de exibir os filmes recomendados na página de recomendação, entrou em atividade os algoritmos de recomendação, que abordaremos nesta seção.

### 3.2.1 Tratamento dos dados

Como já mencionado, na seção acerca da aplicação backend, foi necessário adaptar os dados advindos da base do *TMDb* para a plataforma. Foram extraídas apenas as informações relevantes dos filmes que fariam sentido na aplicação e acrescentado um atributo para sinalizar a média de avaliação dos usuários da própria plataforma, ignorando a já prescrita pela comunidade do *TMDb* (Figura 7).

**Figura 7:** Dados de um filme, em formato JSON.

```
{
  "id": 1,
  "title": "Homem-Aranha: Sem Volta Para Casa",
  "overview": "Peter Parker é desmascarado e não consegue mais separar sua vida normal dos grandes riscos de ser um super-herói. Quando ele pede ajuda ao Doutor Estranho, os riscos se tornam ainda mais perigosos, e o forçam a descobrir o que realmente significa ser o Homem-Aranha.",
  "backdrop_path": "/iQFcwSGbZXMkeyKrxnPnwnRo5fl.jpg",
  "poster_path": "/fVzXp3NwovULLe7fvoRynCmBPnc.jpg",
  "release_date": "2021-12-15",
  "rate_average": 5,
  "main_genre": 28,
  "genre_ids": "[28,12,878]"
}
```

**Fonte:** Elaborado pelo autor (2022).

Vale ressaltar também, a utilização das imagens dos filmes acessados da própria base de dados, cada imagem possuindo um diretório onde acrescido a um domínio base, fornecido na documentação do *TMDb*, possibilitando o acesso da imagem por meio dos navegadores.

No contexto de sistemas de recomendação é comumente observado o problema de *cold start*, ou “partida a frio” traduzido do inglês, que relata sobre na primeira utilização a aplicação não possui dados suficientes para que seja possível identificar alguma similaridade e recomendar algo ao usuário recém chegado. Tendo em vista a resolução deste problema, foi introduzido um usuário inicial com as avaliações de todos os filmes assistidos pelo autor deste trabalho.

Para que pudesse ser aplicada a função de Correlação de Pearson, se fez necessário a realização de uma série de tratamentos e manipulações com os dados, iniciando pela obtenção de todos os usuários e suas interações, conforme Figura 8.

**Figura 8:** Dados de uma interação, em formato JSON.

```
{
  "id": 1,
  "rate": 5,
  "user_id": 2,
  "movie_id": 1,
  "created_at": "2022-03-02T00:54:23.838Z",
  "updated_at": "2022-03-02T00:54:23.838Z"
},
```

**Fonte:** Elaborado pelo autor (2022).

### 3.2.2 Aplicando a filtragem colaborativa

No primeiro passo, a partir das tabelas de interações, é realizado um inner join SQL das tabelas de usuário e filmes do usuário atual e de todos os outros usuários da plataforma, organizando-os de acordo com a Figura 9, logo abaixo.

**Figura 9:** Objeto de interações de um usuário.

```
{
  id: 1,
  name: "Mateus",
  interactions: [
    { rate: 5, movie_id: 75 },
    { rate: 5, movie_id: 146 },
    { rate: 5, movie_id: 154 },
    { rate: 5, movie_id: 46 },
    { rate: 5, movie_id: 47 },
    { rate: 5, movie_id: 139 },
    { rate: 5, movie_id: 70 },
    { rate: 5, movie_id: 110 },
    { rate: 3, movie_id: 176 },
    { rate: 3, movie_id: 26 },
  ],
};
```

**Fonte:** Elaborado pelo autor (2022).

No segundo passo, é formatado o objeto de interações de modo a facilitar o agrupamento dos dados na criação de uma matriz de usuários e filmes. Adicionando um acrônimo ao filme em questão e transformando-o em um atributo do objeto com o valor da avaliação para o filme em questão (Figura 10).

**Figura 10:** Objeto de interações de um usuário e filmes interagidos.

```
[
  {
    id: 1,
    name: 'Mateus',
    'movie-75': 5,
    'movie-146': 5,
    'movie-154': 5,
    'movie-46': 5,
    'movie-47': 5,
    'movie-139': 5,
    'movie-70': 5,
    'movie-110': 5,
    'movie-176': 3,
    'movie-26': 3
  }
]
```

Fonte: Elaborado pelo autor (2022).

**Figura 11:** Representação da matriz de usuários e filmes.

	movie-1	movie-2	movie-3	movie-4
Mateus	5	3	5	4
Carlos	5			4

Fonte: Elaborado pelo autor (2022).

Após os dados de todos os usuários formatados, entra em atividade a função para identificar o coeficiente de correlação de Pearson, verificando a similaridade de cada usuário inscrito na plataforma com o usuário atual.

Conforme organização da matriz (Figura 10 e Figura 11), é possível ver que conseguimos selecionar, mais facilmente, apenas as avaliações em listas.

Enviado as listas para a função responsável por aplicar Pearson, contendo as avaliações de cada usuário com o usuário atual, a função traz como retorno o coeficiente de correlação num valor entre “-1” e “1”, sendo “-1” uma correlação negativa, “0” nenhuma correlação e “1” correlação positiva.

Seguindo o processo, analisando usuário por usuário, é realizada uma ordenação a partir dos mais altos coeficientes de correlação, após isso, é identificado os filmes destes usuários que não possui nenhuma interação do usuário

atual, e enviado uma lista de filmes que de acordo com as interações captadas na plataforma, ainda não foram assistidos pelo usuário atual.

Foram selecionados 2 filmes com as melhores avaliações de cada usuário identificado como similar, onde posteriormente se fez necessário filtrar ainda mais selecionando apenas 7 filmes advindos deste método de filtragem colaborativa, visando facilitar a avaliação dos filmes indicados por parte dos usuários participantes da pesquisa.

### 3.2.3 Aplicando a filtragem baseada em conteúdo

Diferindo do método de filtragem colaborativa que analisou a similaridade de cada usuário de acordo com a avaliação dos filmes interagidos, no método de filtragem baseada em conteúdo, foi analisado a similaridade de cada filme que foi avaliado pelo usuário atual com os outros filmes da base de dados, a partir de uma lista de gêneros, contida nas informações de cada filme.

Os dados foram formatados em objetos contendo o id do filme e a lista de gêneros (Figura 12).

**Figura 12:** Interações de um usuário de acordo com os gêneros.

```
[
  { genre_ids: [ 28, 12, 14, 878 ], id: 11 },
  { genre_ids: [ 28, 12, 14 ], id: 29 },
  { genre_ids: [ 28, 12, 878 ], id: 1 },
  { genre_ids: [ 12, 878, 28 ], id: 154 },
  { genre_ids: [ 12, 14 ], id: 146 },
  { genre_ids: [ 12, 14, 18, 10749 ], id: 196 },
  { genre_ids: [ 12, 28, 878 ], id: 75 },
  { genre_ids: [ 35, 10751, 16 ], id: 215 },
  { genre_ids: [ 35 ], id: 372 },
  { genre_ids: [ 80, 18, 35 ], id: 299 }
]
```

**Fonte:** Elaborado pelo autor (2022).

Também utilizando Pearson, verificando filme por filme, foi enviando a lista de gêneros, gerando assim o coeficiente de correlação de cada filme.

Após todos os filmes ordenados a partir do grau de similaridade, foram selecionados 2 filmes similares a cada filme assistido pelo usuário atual, para

posteriormente selecionar apenas 7 filmes, assim como no método de filtragem colaborativa.

Totalizando 14 filmes recomendados para o usuário, sendo 7 por filtragem colaborativa e 7 selecionados a partir da filtragem baseada em conteúdo.

## 4. APLICAÇÃO

A plataforma foi disponibilizada a um grupo de pessoas, na faixa etária de 18 a 40 anos, a fim de validar a eficácia do sistema de recomendação.

Após identificado, o participante foi redirecionado para a página inicial de coleta de avaliações. A pesquisa foi dividida em duas etapas, na primeira, o participante deveria avaliar pelo menos 10 filmes de sua escolha para que fosse possível prosseguir para a próxima etapa.

O processo de avaliação consistiu em selecionar um filme, e após exibição do modal de informações, selecionar as estrelas, de um a cinco, de acordo com a avaliação do usuário para o filme.

Logo após os 10 primeiros filmes avaliados o usuário é orientado a seguir para a próxima etapa, mas com a possibilidade de continuar avaliando com a justificativa de uma melhor recomendação ao passo que mais filmes forem avaliados.

Na segunda etapa, foram exibidos 14 filmes, recomendados a partir dos algoritmos de recomendação, sendo 7 escolhidos a partir da filtragem colaborativa e 7 indicados a partir da filtragem baseada em conteúdo.

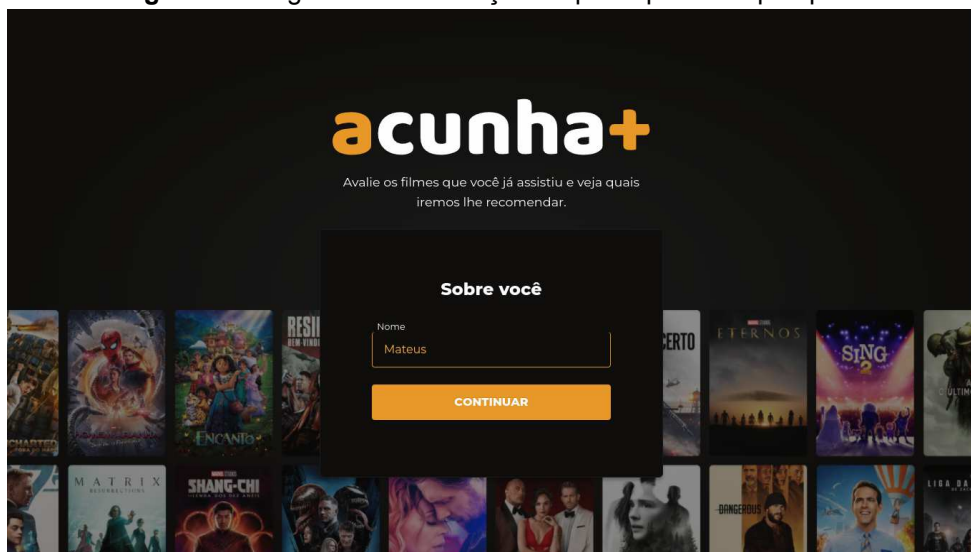
Partindo do ponto que, são filmes que o usuário nunca assistiu, não sendo possível quantificar o quanto ele gostou do filme por meio de estrelas, foi necessário substituir o método de avaliação utilizado na etapa anterior, para o de curti ou não curti, capturando se o usuário gostou ou não da recomendação.

Após a avaliação de todos os filmes recomendados, o processo de pesquisa se encerrou.

### 4.1 Página de identificação

Na tela inicial exibida para os participantes da pesquisa, foi renderizada a página de identificação, desenvolvida com intuito de receber o nome do usuário (Figura 13).

**Figura 13:** Página de identificação do participante da pesquisa.



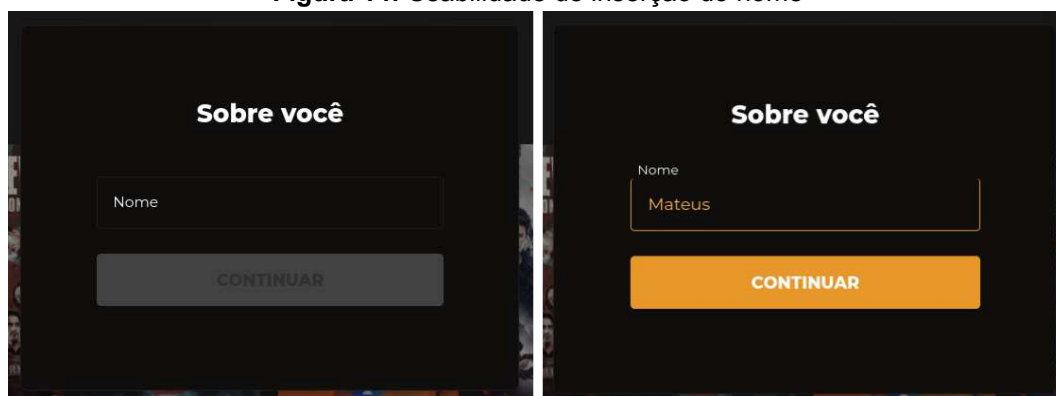
Fonte: Elaborado pelo autor (2022).

Com um *design* bastante característico de aplicações do gênero e pensando em padronizar toda a plataforma, foi construída uma identidade visual própria com cores primárias, secundárias, cores para textos e cores de fundo, bem como, a criação de um logotipo com o nome de *acunha+* (*acunha plus*).

Logo abaixo do logotipo, uma descrição sintetizando todo o intuito da aplicação, seguida de um quadro flutuante para inserção do nome do participante da pesquisa.

Ao clicar no componente de inserção de dados, conhecido como *input*, há uma movimentação do label “Nome” para a parte superior, bem como a mudança na cor das bordas, visando realizar um *feedback* ao usuário informando que foi selecionado. Conforme Figura 14.

**Figura 14:** Usabilidade de inserção do nome



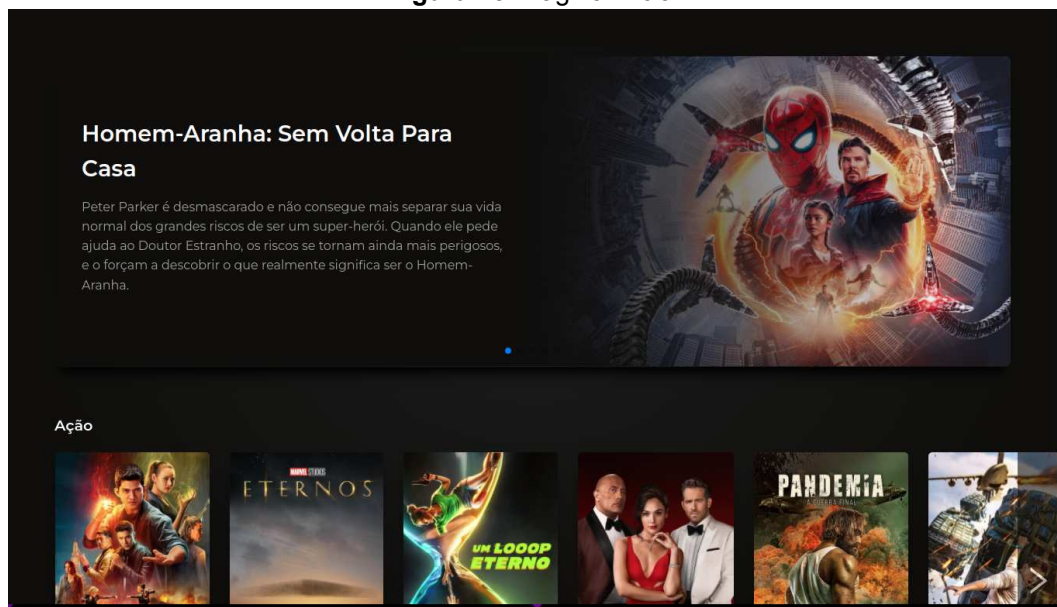
Fonte: Elaborado pelo autor (2022).



## 4.2 Página inicial

Com o intuito de exibir todos os filmes disponíveis na base de dados, de modo a facilitar as interações, a tela inicial foi desenvolvida de modo a manter a consistência e simular as usabilidades já conhecidas por usuários de plataformas de streaming de vídeos (Figura 15).

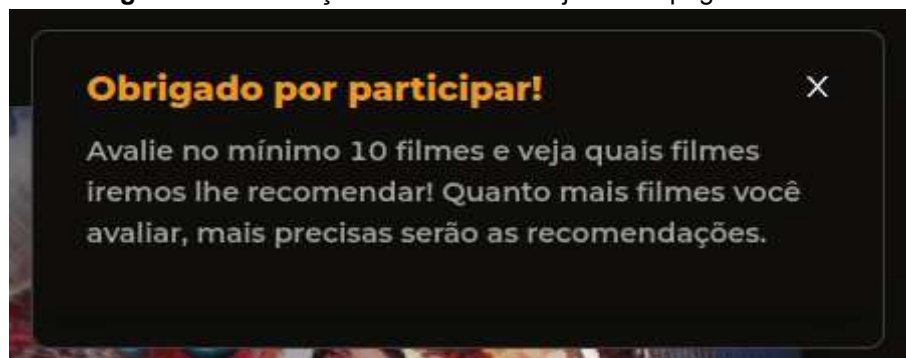
**Figura 15:** Página inicial.



**Fonte:** Elaborado pelo autor (2022).

Logo ao iniciar, e todos os elementos visuais serem carregados na tela, o usuário se depara com uma notificação no topo da tela, informando o objetivo desta primeira tela, conforme Figura 16, logo abaixo.

**Figura 16:** Notificação informando o objetivo da página inicial.



**Fonte:** Elaborado pelo autor (2022).

No topo da tela, foi implementado um carrossel automático com os cinco filmes mais bem avaliados, com uma alternância constante a cada 8 segundos,

exibindo o título, uma breve descrição e uma imagem de divulgação do filme, que ao passar o mouse por cima há uma alteração na cor das bordas, bem como, um acréscimo no tamanho do componente. Conforme Figura 17, logo abaixo.

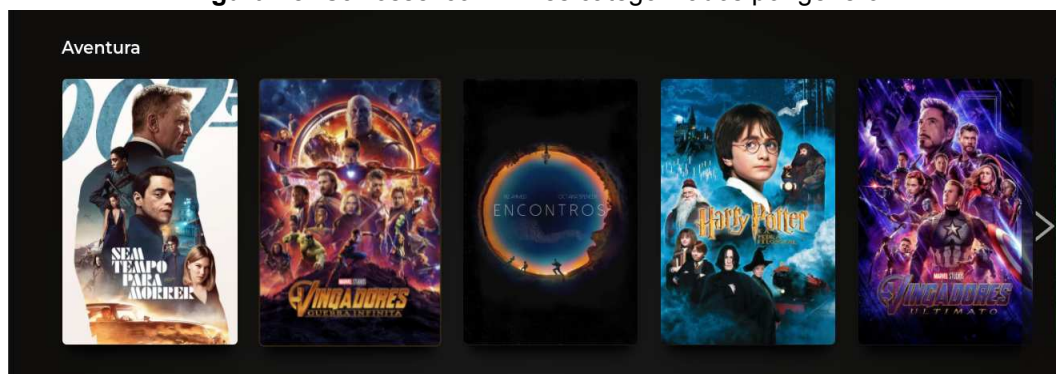
**Figura 17:** Carrossel com os cinco filmes mais populares.



**Fonte:** Elaborado pelo autor (2022).

Logo abaixo, os filmes foram categorizados por gêneros e distribuídos em carrosséis de movimentação manual, por meio de setas laterais (Figura 18).


**Figura 18:** Carrossel com filmes categorizados por gênero.



**Fonte:** Elaborado pelo autor (2022).

Os filmes foram dispostos na tela como cartões retangulares, com um espaçamento padrão entre eles, bordas arredondadas que ao direcionar o mouse, há a exibição do título abaixo do cartão, bem como, a cor das bordas e o tamanho alterados, de modo a possibilitar uma melhor visualização da interação (Figura 19).

**Figura 19:** Usabilidade de visualização do nome de um filme.



**Fonte:** Elaborado pelo autor (2022).

Ao selecionar um filme, clicando em seu cartão, é exibido um modal flutuante com informações. Uma imagem de divulgação do filme selecionado, seguido pelo título, a média de avaliação de todos usuários da plataforma, uma descrição e a possibilidade de avaliá-lo por meio de ícones no formato de estrelas que mudam de cor ao passo que direcionadas com mouse (Figura 20).

**Figura 20:** Modal com informações de um filme.




**Fonte:** Elaborado pelo autor (2022).

O modal foi organizado de modo a trazer uma visibilidade prática de todas as informações principais do filme em questão, utilizando de hierarquias de componentes explicitando o que deve aparecer em primeiro, bem como, hierarquias textuais identificando o que é o título do texto e o que é a descrição (Figura 13).

No canto inferior da tela, segue fixo, o logotipo e uma barra de progresso que se altera de acordo com os filmes vão sendo avaliados, informando ao usuário o quanto falta para que seja possível ir para a próxima etapa, que no caso seria a avaliação de no mínimo dez filmes (Figura 21).


**Figura 21:** Progresso de avaliação de filmes.



Fonte: Elaborado pelo autor (2022).

Após um filme ser avaliado, o seu cartão é alterado para uma coloração sem saturação, distinguindo-o assim dos demais não avaliados, possibilitando ao usuário uma melhor identificação de todos os filmes já interagidos (Figura 22).

**Figura 22:** Cartão de um filme após ser avaliado.



Fonte: Elaborado pelo autor (2022).

No momento que avaliados os dez filmes, é exibido no topo da tela uma notificação informando o encerramento desta primeira etapa, como também, a barra

de progresso é substituída por um botão responsável para direcionar para a próxima etapa (Figura 23).

**Figura 23:** Notificação informando o encerramento da primeira etapa.



Fonte: Elaborado pelo autor (2022).

### 4.3 Página de recomendações

Logo ao ser introduzido na segunda etapa, o usuário é informado por meio de uma notificação sobre o seu objetivo (Figura 24).

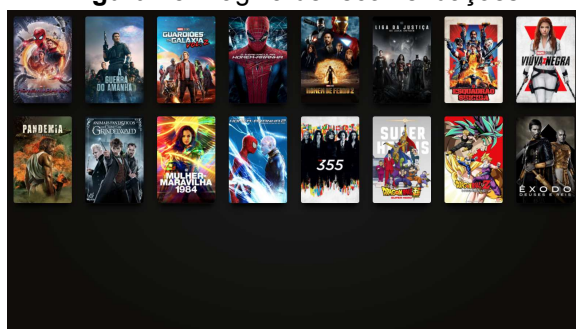
**Figura 24:** Notificação informando o objetivo da página de recomendações.



Fonte: Elaborado pelo autor (2022).

Organizada de modo livre, a segunda etapa que é realizada na página de recomendações, os filmes são dispostos sem o uso do carrossel um após o outro, com a mesma usabilidade dos cartões de filmes da página inicial, exceto pelo modal de detalhes do filme que há uma alteração no método de avaliação (Figura 25).


**Figura 25:** Página de recomendações.



Fonte: Elaborado pelo autor (2022).



**Figura 26:** Modal com informações de um filme, na página de recomendações.



**Fonte:** Elaborado pelo autor (2022).

#### 4.4 Página final

Após todos os filmes recomendados serem avaliados, o usuário é direcionado para a página final, com informes sobre o encerramento e agradecendo-o pela participação (Figura 27). Os métodos de filtragem utilizados na pesquisa foram destacados e ao lado deles, um ícone indicando mais informações que ao mover o mouse é exibido uma síntese sobre como funciona cada método.

**Figura 27:** Página final.



**Fonte:** Elaborado pelo autor (2022).

No fim da página, ícones com links direcionando para o *Github* (*Plataforma de hospedagem de código fonte*) e o *Linkedin* (*Rede social profissional*) do autor deste trabalho.

## 5. RESULTADOS

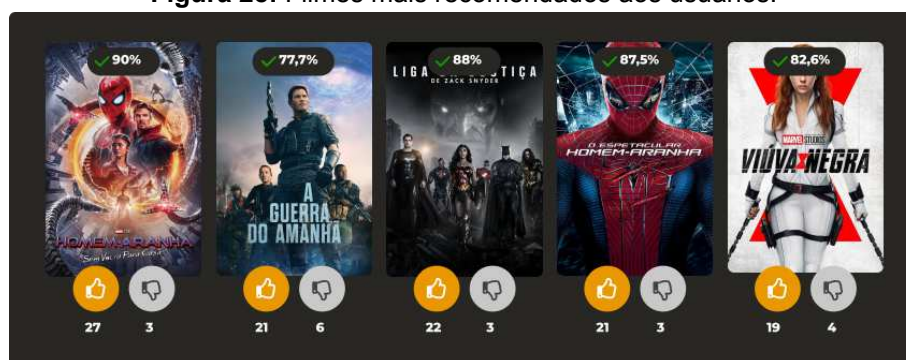
Ao todo, 41 pessoas participaram da pesquisa, sendo uma delas o autor deste trabalho a fim de resolver o problema de *cold start* como mencionado anteriormente, avaliando em livre escolha os filmes assistidos e avaliando as recomendações que eram indicadas pelo sistema.

Em uma base com 1000 filmes, foram avaliados 230 na etapa inicial da pesquisa, com um total de 598 interações capturadas.

Na segunda etapa, foram capturadas 567 interações, a partir de 148 filmes recomendados.

Analisando as interações com todos os filmes recomendados, pode-se observar uma taxa de 76% (setenta e seis por cento) de aprovação.

**Figura 28:** Filmes mais recomendados aos usuários.



Fonte: Elaborado pelo autor (2022).

Dos filmes mais recomendados aos usuários, destaca-se o top 5 (Figura 28).

- “Homem-Aranha: Sem Volta Para Casa”, recomendado a 30 usuários, com uma taxa de aprovação de 90% (noventa por cento);
- “A guerra do amanhã”, recomendado a 27 usuários, com uma aprovação de 77,7% (setenta e sete inteiros e sete décimos por cento);
- “Liga da Justiça de Zack Snyder”, indicado a 25 usuários, com 88% (oitenta e oito inteiros e oito décimos por cento) de aprovação;
- “O Espetacular Homem-Aranha”, recomendado a 24 usuários, com 87,5% (oitenta e sete inteiros e cinco décimos por cento);
- “Viúva Negra”, recomendado a 23 usuários com uma aprovação de 82,6% (oitenta e dois inteiros e seis décimos por cento).



## 6. CONSIDERAÇÕES FINAIS

Com este trabalho foi possível analisar a eficácia e exemplificar, de modo prático, a implementação dos métodos de filtragem colaborativa e filtragem baseada em conteúdo, demonstrando toda a arquitetura e fluxo de um sistema de recomendação.

No decorrer do desenvolvimento, tornou-se conhecido alguns dos conceitos mais substanciais acerca do planejamento e desenvolvimento de um software, bem como, a demonstração de algumas das tecnologias mais utilizadas atualmente.

Após a análise das interações dos usuários, a pesquisa concluiu-se com uma ótima taxa de aprovação dos filmes recomendados aos participantes da pesquisa, explicitando o quão necessários são os algoritmos de recomendação para um ambiente que visa o consumo de produtos ou serviços em geral.

Embora este projeto visou exemplificar e analisar a eficácia de cada método individualmente, observou-se que, os utilizando-os em conjunto é possível chegar a um maior índice de aprovação, aplicando o que há de melhor em cada um dos métodos.

Como proposta para continuidade desta pesquisa, sugerimos a implementação de uma abordagem híbrida utilizando os dois métodos de filtragem. Identificando os usuários semelhantes ao usuário atual e utilizando aos seus filmes, que não foram assistidos pelo usuário atual, o método de filtragem baseada em conteúdo.

Outra proposta seria de utilizar tais conceitos e algoritmos abordados neste projeto, em outros segmentos, como por exemplo recomendação de livros, roupas, e outros dos mais diversos tipos de produtos e serviços consumíveis, que possam vir a se beneficiar com a utilização de um sistema de recomendação.

## REFERÊNCIAS BIBLIOGRÁFICAS

LUIZ, José. **Uma abordagem híbrida para sistemas de recomendação de notícias**. Universidade Federal da Bahia, 2018. Disponível em: <<http://repositorio.ufba.br/ri/handle/ri/27622>>. Último acesso em: 11 de outubro de 2021.

JARDIM, Camila. **Uma introdução aos sistemas de recomendação: modelos matemáticos, algoritmos e aplicações**. Universidade Estadual de Campinas, 2020. Disponível em: <[http://repositorio.unicamp.br/bitstream/REPOSIP/357552/1/Bonilha\\_CamilaJardimCavalcante\\_M.pdf](http://repositorio.unicamp.br/bitstream/REPOSIP/357552/1/Bonilha_CamilaJardimCavalcante_M.pdf)>. Último acesso em: 11 de outubro de 2021.

JOSÉ, Ralph. **Aprendizado neural de representação de conteúdo para sistema de recomendação de filmes**. Pontifícia Universidade Católica do Rio Grande do Sul, 2017. Disponível em: <<http://tede2.pucrs.br/tede2/handle/tede/7740>>. Último acesso em: 11 de outubro de 2021.

GOMEDE, Everton. **Arquiteturas de Redes Neurais Artificiais para Aprendizado Adaptativo em Sistemas de E-learning**, 2020. Disponível em: <<http://repositorio.unicamp.br/jspui/handle/REPOSIP/349247>>. Último acesso em: 11 de outubro de 2021.

WILSON, David. **Predição de popularidade em mídia social utilizando uma rede de atenção hierárquica**, 2019. Disponível em: <<https://repositorio.ufpe.br/handle/123456789/35365>>. Último acesso em: 11 de outubro de 2021.

MONTEIRO, Luciana; PORT, Rafael; RIBEIRO, Cristina. **Quem leu este também leu...: sistema de recomendação na biblioteca universitária**, 2017. Disponível em: <<https://www.scielo.br/j/pci/a/SDGHfxzHppxDDPcm6GmW8SD/abstract/?lang=pt>>. Último acesso em: 11 de outubro de 2021.

MOISINHO, Aline M.; DA SILVA, Emilly G. M.; JUNIOR, Paulo F. S.; SCHNEIDER, Daniel; MOTTA, Claudia L. R.. **Modelo conceitual para sistemas de recomendação voltados a governo eletrônico com o uso do cadastro base do cidadão**, 2021. Disponível em: <<https://sol.sbc.org.br/index.php/wcge/article/view/15990>>. Último acesso em: 11 de outubro de 2021.

DAMASCENO, João. **O algoritmo e o fluxo: Netflix, aprendizado de máquina e algoritmos de recomendações**, 2019. Disponível em: <<https://seer.ufrgs.br/intexto/article/view/83748>>. Último acesso em: 11 de outubro de 2021.

NETFLIX. **Como funciona o sistema de recomendações da Netflix**, 2021. Disponível em: <<https://help.netflix.com/pt/node/100639>>. Último acesso em: 11 de outubro de 2021.

REATEGUI, Eliseo; CÉSAR, Sílvio; AUGUSTA, Maria. **A Ciência da Opinião: Estado da arte em Sistemas de Recomendação**, Disponível em: <<http://almanaquesdacomputacao.com.br/gutanunes/publications/JAI4.pdf>>. Último acesso em: 11 de outubro de 2021.

FIGUEIREDO, Arthur. **SISTEMAS DE RECOMENDAÇÃO E FEED DE NOTÍCIAS: Um estudo sobre a difusão de ideologias na rede social virtual Facebook**, 2021. Disponível em: <<https://repositorio.ufsc.br/handle/123456789/223741>>. Último acesso em: 11 de outubro de 2021.

ADOMAVICIUS, G.; TUZHILIN, A. **Toward the Next Generation of Recommender Systems: a Survey of the State of the Art and Possible Extensions**. IEEE Transactions on Knowledge and Data Engineering, 2005. Disponível em: <<https://ieeexplore.ieee.org/document/1423975>>. Último acesso em: 11 de outubro de 2021.

REATEGUI, E.B. E CAZELLA, S.C.- **Sistemas de Recomendação, Anais do Encontro Nacional de Inteligência Artificial – XXV Congresso da Sociedade Brasileira de Computação**, 2005. Disponível em: <<https://sistemascolaborativos.uniriotec.br/wp-content/uploads/sites/18/2019/06/SC-cap15-recomendacao.pdf>>. Último acesso em: 11 de outubro de 2021.

NEVES, Rodrigo. **Fidelidade de protótipos: Baixa, Média ou Alta, conheça os tipos**, 2017. Disponível em: <<https://www.vitaminaweb.com.br/fidelidade-de-prototipos-baixa-media-ou-alta/>>. Último acesso em: 12 de março de 2022.

FABRO, Clara. **O que é API e para que serve? Cinco perguntas e respostas**, 2020. Disponível em: <<https://www.techtudo.com.br/listas/2020/06/o-que-e-api-e-para-que-serve-cinco-perguntas-e-respostas.ghtml>>. Último acesso em: 13 de março de 2022.

ISINKAYE, Folasade Olubusola; FOLAJIMI, Yetunde O; OJOKOH, Bolande Adefowo. **Recommendations systems: Principles, methods and evaluation**, 2015. Disponível em: <<https://reader.elsevier.com/reader/sd/pii/S1110866515000341?token=728A55C9DB47B5AB5EF2FD2405D127870E2F67992BA0087EF18216E330AADB58F0936E6625DC89A38AC0D2170F0F2D21&originRegion=us-east-1&originCreation=20220622014149>>. Último acesso em: 21 de Junho de 2022.

KUMAR, Mallari Vijay; KUMAR, Pavan. **A Study on Different Phases and Various Recommendation System Techniques**, 2019. <<https://www.ijrte.org/wp-content/uploads/papers/v7i5c/E10100275C19.pdf>>. Último acesso em: 21 de Junho de 2022.