



UEPB

**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS VII — GOVERNADOR ANTÔNIO MARIZ
CENTRO DE CIÊNCIAS EXATAS E SOCIAIS APLICADAS
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

ARTHUR MEDEIROS DE OLIVEIRA

**A INFLUÊNCIA DOS ALGORITMOS DE
RECOMENDAÇÃO NA CRIAÇÃO E CONSUMO DE
CONTEÚDO FUTEBOLÍSTICO**

**PATOS – PB
2024**

ARTHUR MEDEIROS DE OLIVEIRA

**A INFLUÊNCIA DOS ALGORITMOS DE
RECOMENDAÇÃO NA CRIAÇÃO E CONSUMO DE
CONTEÚDO FUTEBOLÍSTICO**

Trabalho de Conclusão do Curso apresentado à coordenação do curso de Graduação em Ciência da Computação do Centro de Ciências Exatas e Sociais Aplicadas da Universidade Estadual da Paraíba, como requisito parcial à obtenção do título de Bacharel em Ciência da Computação.

Área de concentração: Inteligência Artificial

Orientador: Prof. Dr. Janderson Jason Barbosa Aguiar

PATOS – PB
2024

É expressamente proibida a comercialização deste documento, tanto em versão 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.

O48i Oliveira, Arthur Medeiros de.
A influência dos algoritmos de recomendação na criação e consumo de conteúdo futebolístico [manuscrito] / Arthur Medeiros de Oliveira. - 2024.
57 f. : il. color.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Ciência da computação) - Universidade Estadual da Paraíba, Centro de Ciências Exatas e Sociais Aplicadas, 2024.

"Orientação : Prof. Dr. Janderson Jason Barbosa Aguiar, Coordenação do Curso de Computação - CCEA".

1. Sistemas de recomendação. 2. Futebol. 3. Vídeos. 4. Youtube. I. Título

21. ed. CDD 006.35

ARTHUR MEDEIROS DE OLIVEIRA

A INFLUÊNCIA DOS ALGORITMOS DE RECOMENDAÇÃO NA CRIAÇÃO E
CONSUMO DE CONTEÚDO FUTEBOLÍSTICO

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

Aprovada em: 19/11/2024.

Documento assinado eletronicamente por:

- **Suellen Rodrigues Ramos da Silva** (**.528.604-**), em **30/11/2024 00:18:01** com chave **b4e9a8b8aec911ef910206adb0a3afce**.
- **Janderson Jason Barbosa Aguiar** (**.765.854-**), em **30/11/2024 00:17:46** com chave **ab9d06c4aec911ef86ec2618257239a1**.
- **Jannayna Domingues Barros Figueira** (**.837.144-**), em **30/11/2024 16:47:17** com chave **e7dfedf6af5311efa59a06adb0a3afce**.

Documento emitido pelo SUAP. Para comprovar sua autenticidade, faça a leitura do QrCode ao lado ou acesse https://suap.uepb.edu.br/comum/autenticar_documento/ e informe os dados a seguir.

Tipo de Documento: Termo de Aprovação de Projeto Final

Data da Emissão: 30/11/2024

Código de Autenticação: 8bea37



AGRADECIMENTOS

Primeiramente quero agradecer a Deus, que me guiou ao longo do curso, especialmente nos momentos de incerteza e angústia. Sem Ele não conseguiria superar todos os desafios enfrentados. Sou grato por ter sido conduzido pelo caminho da sabedoria e por ter recebido força para concluir mais uma etapa importante na minha vida

À minha família, que me apoiou em alguns momentos. Aos meus pais, sem seus esforços e incentivo, não estaria onde estou hoje. Foram e continuam sendo minha rede de apoio, incentivando e aconselhando da melhor forma possível, mesmo sem entenderem a área de computação.

Aos meus colegas e amigos, que me acompanharam durante toda minha vida acadêmica, proporcionando momentos de alegrias e angústias. Vocês tornaram essa jornada um pouco mais fácil, com histórias e risadas que ajudaram a enfrentar os desafios com ânimo renovado.

Ao meu orientador Dr. Janderson Jason Barbosa Aguiar, quero expressar minha sincera gratidão pelos ensinamentos compartilhados e por aceitar o desafio de me orientar no meu trabalho. Obrigado por contribuir na minha vida acadêmica, sempre lembrarei de cada ensinamento. Também agradeço às professoras Jannayna Domingues Barros Figueira e Suéllen Rodrigues Ramos da Silva, que aceitaram gentilmente fazer parte da minha banca examinadora e por serem peça fundamental nessa etapa crucial da minha vida.

Por fim, gostaria de agradecer à Universidade Estadual da Paraíba, que se tornou um lugar para meu crescimento pessoal e profissional. A todos os professores, meu sincero agradecimento pelos ensinamentos valiosos, pelas experiências e conselhos que foram dados ao longo desses anos.

“Não fui eu que lhe ordenei? Seja forte e corajoso! Não se apavore nem desanime, pois o Senhor, o seu Deus, estará com você por onde você andar.”

Josué 1:9

RESUMO

Com o crescimento das plataformas digitais, como o YouTube, os sistemas de recomendação tornaram-se ferramentas essenciais para personalizar a experiência do usuário e influenciar o consumo de conteúdo. No universo do futebol, a criação e o consumo de vídeos são diretamente impactados por essas tecnologias, que moldam tanto as preferências dos espectadores quanto as estratégias dos criadores de conteúdo. Este trabalho analisa como o consumo e a produção de conteúdo futebolístico na plataforma do YouTube podem ser impactados pelas técnicas de filtragem aplicadas em sistemas de recomendação. A metodologia incluiu uma revisão bibliográfica, seguida pela coleta e análise de dados reais, além da implementação de um protótipo simples que combinou técnicas de filtragem colaborativa e baseada em conteúdo. Embora o estudo tenha se concentrado em um número limitado de canais e utilizado dados fictícios no protótipo, o que restringe a generalização dos resultados, foi possível obter uma visão geral sobre o impacto das recomendações na experiência dos usuários e na produção de conteúdo. O estudo enfatiza a importância dos sistemas de recomendação na personalização da experiência do usuário e na formulação das estratégias de criação de conteúdo, especialmente em canais esportivos no YouTube. Dessa forma, este trabalho contribui para a compreensão dos mecanismos de recomendação na plataforma, oferecendo informações pertinentes sobre como esses sistemas influenciam tanto os usuários quanto os criadores de conteúdo, especialmente no contexto esportivo.

Palavras-chave: sistemas de recomendação; futebol; vídeos; YouTube.

ABSTRACT

With the growth of digital platforms such as YouTube, recommender systems have become essential tools for personalizing the user experience and influencing content consumption. In football, these technologies directly impact the creation and consumption of videos, shaping viewers' preferences and content creators' strategies. This study analyzes how the consumption and production of football content on the YouTube platform can be impacted by filtering techniques applied in recommender systems. The methodology included a literature review, the collection and analysis of real data, and the implementation of a simple prototype that combined collaborative and content-based filtering techniques. Although the study focused on a limited number of channels and used fictitious data in the prototype, which limits the generalizability of the results, it was possible to obtain an overview of the impact of recommendations on user experience and content production. The study emphasizes the importance of recommender systems in personalizing the user experience and formulating content creation strategies, especially on sports channels on YouTube. In this way, this work contributes to the understanding of recommendation mechanisms on the platform, offering pertinent information on how these systems influence both users and content creators, especially in the sports context.

Keywords: recommender systems; football; videos; YouTube.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo 1 da Filtragem Colaborativa	16
Figura 2 – Exemplo 2 da Filtragem Colaborativa	16
Figura 3 – Exemplo 1 da Filtragem Baseada em Conteúdo	17
Figura 4 – Exemplo 2 da Filtragem Baseada em Conteúdo	18
Figura 5 – Gráfico de Crescimento ao longo do tempo do canal Goat	28
Figura 6 – Gráfico de Crescimento ao longo do tempo do canal CazéTV	29
Figura 7 – Gráfico de Crescimento ao longo do tempo do canal ESPN Brasil	30
Figura 8 – Gráfico de Crescimento ao longo do tempo do canal TNT Sports Brasil	31
Figura 9 – Gráfico de Crescimento ao longo do tempo do canal GE	32
Figura 10 – Gráfico de Crescimento ao longo do tempo do canal Gonze Neles	33
Figura 11 – Gráfico de Crescimento ao longo do tempo do canal Jogo Aberto	34
Figura 12 – Gráfico de Crescimento ao longo do tempo do canal Desimpedidos	35
Figura 13 – Gráfico de Crescimento ao longo do tempo do canal Confederação Brasileira de Futebol	36
Figura 14 – Gráfico de Crescimento ao longo do tempo do canal Gol de Canela	37
Figura 15 – Gráfico de Crescimento ao longo do tempo do canal Futebol pelo Mundo	38
Figura 16 – Gráfico de Crescimento ao longo do tempo do canal Futirinhas	39
Figura 17 – Gráfico de Crescimento ao longo do tempo do canal Modo Carreira Soto	40
Figura 18 – Diagrama do protótipo	42
Figura 19 – Vídeos recomendados para cada usuário	46

LISTA DE QUADROS

Quadro 1 – Canais coletados	26
---------------------------------------	----

LISTA DE ABREVIATURAS E SIGLAS

SRs	Sistemas de Recomendação
FC	Filtragem Colaborativa
FBC	Filtragem Baseada em Conteúdo
DSR	<i>Design Science Research</i>
CBF	Confederação Brasileira de Futebol

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Contexto e problemática	12
1.2	Justificativa	12
1.3	Objetivos	13
1.3.1	<i>Objetivo geral</i>	13
1.3.2	<i>Objetivos específicos</i>	13
1.4	Estrutura do documento	14
2	REFERENCIAL TEÓRICO	15
2.1	Sistemas de recomendação	15
2.1.1	<i>Filtragem colaborativa</i>	15
2.1.2	<i>Filtragem baseada em conteúdo</i>	17
2.2	Conteúdo esportivo online	18
2.2.1	<i>Engajamento do usuário</i>	18
2.2.2	<i>Desafios e oportunidades na produção de conteúdo esportivo online</i>	19
2.3	Evolução dos sistemas de recomendação e seu impacto no conteúdo esportivo	20
2.3.1	<i>Evolução para personalização do conteúdo</i>	20
2.3.2	<i>Impacto no consumo e produção de conteúdo esportivo</i>	20
3	METODOLOGIA	22
3.1	Tipo de pesquisa	22
3.2	Revisão da literatura	22
3.3	Coleta de dados	23
3.3.1	<i>Armazenamento dos dados</i>	23
3.3.2	<i>Análise qualitativa e quantitativa</i>	23
3.4	Protótipo de sistema de recomendação	24
3.5	Breve estudo de caso	24
4	RESULTADOS E DISCUSSÃO	26
4.1	Avaliação referente aos Canais	26
4.1.1	<i>Dados coletados</i>	26
4.1.2	<i>Análise dos canais</i>	27
4.2	Implementação do protótipo e breve estudo de caso	41
4.2.1	<i>Bibliotecas importadas</i>	42
4.2.2	<i>Criação dos perfis de usuários e vídeos</i>	42
4.2.3	<i>Histórico de interações</i>	43

4.2.4	<i>Funções para recomendação por filtragem colaborativa e baseada em conteúdo</i>	44
4.2.5	<i>Função híbrida</i>	44
4.2.6	<i>Gerar recomendação para cada usuário</i>	45
4.2.7	<i>Estudo de caso reduzido</i>	45
5	CONSIDERAÇÕES FINAIS	47
5.1	Conclusões	47
5.2	Limitações e sugestões para estudos futuros	48
	REFERÊNCIAS	50
	APÊNDICE A – PROTÓTIPO	54

1 INTRODUÇÃO

O futebol é um dos esportes mais populares do mundo, atraindo milhões de fãs ao redor do mundo. A transformação tecnológica alterou profundamente a maneira como o público consome e interage com o futebol. Os algoritmos de recomendação desempenham um papel importante nesse processo, sugerindo vídeos de acordo com as preferências de cada usuário, transformando a produção, descoberta e consumo de conteúdo.

1.1 Contexto e problemática

Segundo pesquisa do UOL (2024), o futebol é o esporte mais popular entre os brasileiros, com 78% acompanhando esta modalidade. O crescimento do *streaming* impulsionou esse interesse, alcançando 1,2 bilhão de visualizações apenas no Campeonato Paulista de 2022 (Brandini; Machado; Montagner, 2023). Após 30 anos de domínio das transmissões de TV aberta e fechada, os serviços de *streaming* cresceram devido à aquisição de direitos e estratégias de marketing (Simon, 2024).

Enquanto os pacotes de *streaming*, como Premiere e Star+, oferecem competições específicas, o YouTube oferece uma plataforma diversificada para o consumo esportivo. Canais como CazéTV, Desimpedidos e Gonze Neles ajudam a popularizar o futebol na plataforma, com conteúdos variados e atrativos. O Youtube oferece autonomia para informar de forma criativa todos os aspectos desse esporte, desde análises até histórias do futebol, tornando-se uma fonte importante de informações sobre futebol.

Segundo o site Exame (2023), o canal CazéTV obteve 69 milhões de visualizações durante os 64 jogos da Copa do Mundo Feminina de 2023, com transmissões e conteúdos diversos. Esse ambiente acessível permite que o público continue acompanhando o esporte, mesmo após os fins dos jogos, por meio de replays, análises, reações e conteúdos complementares (Moreschi; Majer, 2022).

Com a popularidade crescente do *streaming* e a variedade de conteúdo esportivo no YouTube, os usuários enfrentam uma sobrecarga de informações, dificultando a descoberta de conteúdos que satisfaçam seus interesses. Nesse contexto, sistemas de recomendação personalizados se tornam essenciais para melhorar a experiência do usuário, permitindo que encontrem vídeos de futebol mais alinhados às suas preferências.

Dado esse contexto, a questão motivadora desta pesquisa pode ser expressa da seguinte forma: “Como os sistemas de recomendação podem influenciar na experiência dos usuários no consumo de conteúdos relacionados ao futebol?”.

1.2 Justificativa

A capacidade de recomendar vídeos de acordo com os interesses e preferências dos usuários é enorme. Dentre os diversos tipos de conteúdo disponíveis, os de futebol têm

grande audiência, sendo evidente em uma das plataformas mais populares do mundo, o YouTube, na qual milhões de vídeos são carregados e visualizados diariamente.

Um estudo de Muratori (2021) alega que as pessoas sentiriam falta da plataforma caso deixasse de existir, devido ao poder de escolha e à personalização do conteúdo que assistem. O estudo também destaca que no Brasil, 1/3 dos entrevistados assistem ao YouTube pela TV, muitas vezes em grupo, o que influencia o interesse esportivo alinhado com seus interesses. Esse consumo é facilitado pela portabilidade da plataforma, acessível em diversos dispositivos.

Além dos benefícios para os usuários, compreender o algoritmo de recomendação é uma vantagem estratégica para os criadores de conteúdo. O YouTube (2023) revela que a plataforma utiliza dados como o histórico de exibição e de pesquisa, inscrições em canais, marcações “Gostei” e “Não gostei”, seleções de *feedback* “Não tenho interesse” e “Não recomendar o canal”, e pesquisas de satisfação, como parâmetros para recomendar vídeos.

Criadores que compreendem esses mecanismos conseguem alinhar melhor o conteúdo produzido para atender ao que os espectadores desejam, impactando positivamente no alcance e no engajamento dos vídeos. Quando essas recomendações atingem um bom desempenho, a plataforma consegue conectar bilhões de pessoas ao redor do mundo (YouTube, 2023).

Esse entendimento permite que os criadores ajustem suas estratégias para aumentar a visibilidade de seus vídeos, ampliando as chances de que sejam recomendados a um público mais diversificado. Consequentemente, a interação entre plataforma, criadores e o público impulsiona o consumo futebolístico no Youtube, beneficiando todos os envolvidos.

1.3 Objetivos

1.3.1 *Objetivo geral*

Explorar e estudar os processos de recomendação de vídeos de futebol, buscando entender como podem influenciar a experiência dos usuários e a criação de conteúdo.

1.3.2 *Objetivos específicos*

1. Estudar as técnicas existentes de recomendação de itens, com enfoque no contexto de vídeos de futebol na plataforma do YouTube.
2. Investigar como técnicas de recomendação podem aumentar o engajamento e a satisfação do público que consome vídeos de futebol.
3. Compreender como a recomendação de vídeos de futebol influencia nas estratégias de produção de vídeos.

4. Desenvolver protótipo para praticar os conceitos estudados e sugerir uma forma de recomendação de vídeos mais personalizada.

1.4 Estrutura do documento

O trabalho está organizado da seguinte maneira. Neste capítulo 1, é apresentada a Introdução, destacando a influência das mídias sociais no consumo de conteúdo futebolístico. Também foi discutida a importância da plataforma do YouTube e apresentados os objetivos geral e específicos.

O capítulo 2 contém a Fundamentação Teórica, analisando como os sistemas de recomendação funcionam de forma geral. Além disso, é debatido sobre a nova realidade de conteúdo esportivo online.

O capítulo 3 detalha a Metodologia utilizada durante toda a pesquisa, detalhando a coleta de dados e as tecnologias utilizadas para implementar o protótipo do sistema de recomendação.

O Capítulo 4 concentra-se nos Resultados e Discussões, apresentando análises qualitativas e quantitativas dos dados coletados, com quadro e gráficos. Além disso, detalha a implementação, especificando as bibliotecas e funções utilizadas, e discute o estudo de caso simplificado.

O capítulo 5 inclui as Considerações Finais, resumindo os principais assuntos abordados no trabalho, destacando as contribuições e expondo possibilidades de pesquisas futuras. Por fim, são apresentadas as Referências usadas neste trabalho.

2 REFERENCIAL TEÓRICO

Neste capítulo, são apresentados os principais conceitos teóricos para sustentar a pesquisa. Na Seção 2.1, são apresentados os Sistemas de Recomendação, com enfoque em duas de suas filtragens. Na Seção 2.2, é mostrado como as recomendações influenciam no conteúdo esportivo, com o foco no futebol. Na Seção 2.3 são comentados a evolução e o impacto no nicho esportivo. Por fim, na Seção 2.4, são expostas as considerações finais do capítulo.

2.1 Sistemas de recomendação

Com a popularidade da internet, as pessoas desejam acessar conteúdos facilmente, por isso os Sistemas de Recomendação (SRs) são importantes, pois, com as filtragens realizadas, as pessoas conseguem adquirir informações detalhadas sobre o que elas desejam encontrar de maneira fácil e rápida.

Os SRs funcionam como salva-vidas no mar de dados (Santos *et al.*, 2024) devido ao grande número de informações, filtrando materiais relevantes. Para que isso ocorra, o sistema deve estar qualificado para prever a importância dos dados e poder sugerir (Santos; Duraó, 2023).

Diante da ampla extensão de informações, os SRs utilizam vários tipos de filtragem para conseguir e garantir a antecipação de possíveis resultados, como a filtragem colaborativa, a filtragem baseada em conteúdo e a filtragem híbrida. Esta última consiste na união das outras duas, com uso comum em redes sociais, como Instagram, Facebook e YouTube (Bobadilla *et al.*, 2013).

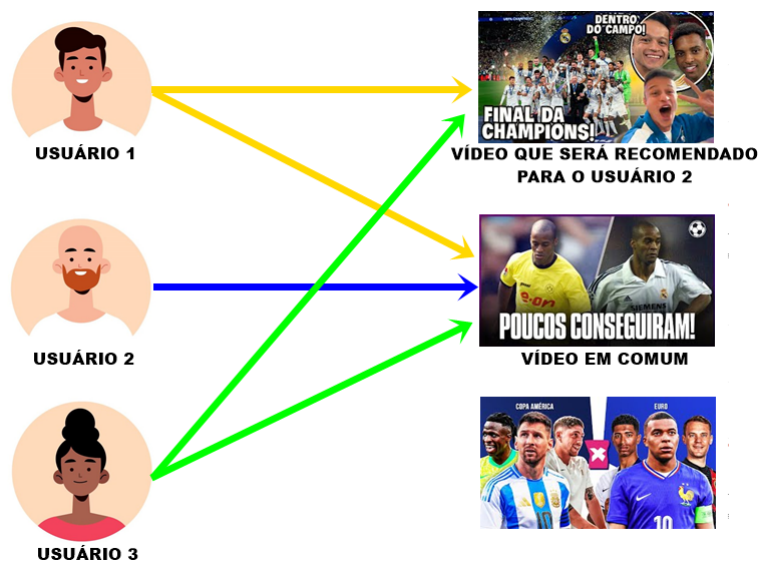
2.1.1 Filtragem colaborativa

Bobadilla *et al.* (2013) explicam que a Filtragem Colaborativa (FC) se apoia na maneira que as pessoas tomam decisões durante o consumo de conteúdo, utilizando dados de interações passadas de diversos usuários para prever as preferências futuras, fornecendo uma recomendação personalizada.

Com esse intuito, a FC tem como base as escolhas que os usuários fazem, como assistir, curtir, comentar e compartilhar os vídeos. Em seguida, é realizada a ligação entre os usuários, recomendando vídeos desconhecidos, mas que são conhecidos e avaliados como relevantes por outros usuários com preferências iguais, gerando itens para que o usuário possa consumir (Aguiar; Araujo; Costa, 2020).

Como exemplo, há o YouTube, que utiliza as interações dos usuários para recomendar vídeos de forma personalizada. Ele analisa o histórico de visualizações, curtidas e comentários, gerando conteúdo que provavelmente desperte interesse do usuário, melhorando as recomendações individuais.

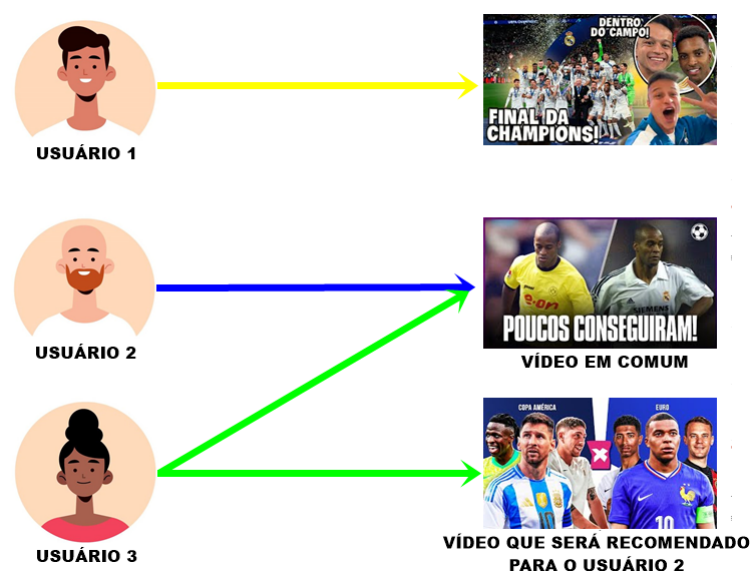
Figura 1 – Exemplo 1 da Filtragem Colaborativa



Fonte: autoria própria (2024).

Ao observar a Figura 1, o usuário 2 assistiu ao segundo vídeo, assim como os outros usuários. Dessa forma, o algoritmo de FC analisará os vídeos assistidos pelas outras pessoas, recomendando vídeos que o usuário 2 não assistiu e que apresenta as melhores métricas, neste caso, o primeiro vídeo. Já na Figura 2, o terceiro vídeo é o ideal a ser recomendado, devido à similaridade entre o usuário 2 e 3, ao terem assistido o segundo.

Figura 2 – Exemplo 2 da Filtragem Colaborativa



Fonte: autoria própria (2024).

Contudo, na FC, existe um problema chamado *cold-start*, que ocorre quando o sistema não possui dados suficientes sobre novos usuários ou itens, dificultando a geração de recomendações personalizadas (Quirino, 2022). À medida que os usuários interagem

com novos itens (por exemplo, novos vídeos), o sistema coleta mais informações, o que possibilita a geração de recomendações mais precisas e adaptadas ao perfil de cada usuário.

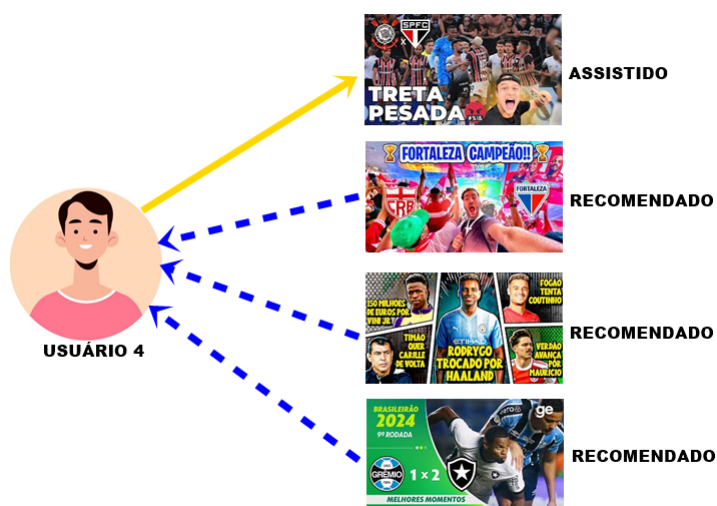
2.1.2 Filtragem baseada em conteúdo

Segundo Felfernig *et al.* (2024), a Filtragem Baseada em Conteúdo (FBC) é capaz de analisar o que o usuário consumiu, identificando as características dos itens visualizados para fornecer uma recomendação personalizada. Ademais, a FBC não considera as preferências de outros usuários, limitando o problema de *cold-start*. Dessa forma, o sistema apresenta sugestões relevantes baseadas no conteúdo assistido pelas pessoas.

Ao observar as Figuras 3 e 4, há duas formas distintas de recomendação. Na Figura 3, o usuário 4 assistiu ao primeiro vídeo do canal Gonze Neles. Com isso, três novos vídeos foram indicados: um do canal Futebol pelo Mundo, devido à mesma linha de conteúdo; outro do canal Futirinhas, relacionado ao Corinthians, dado que o vídeo assistido trata-se de um jogo da equipe; e um do canal GE, referente ao Campeonato Brasileiro.

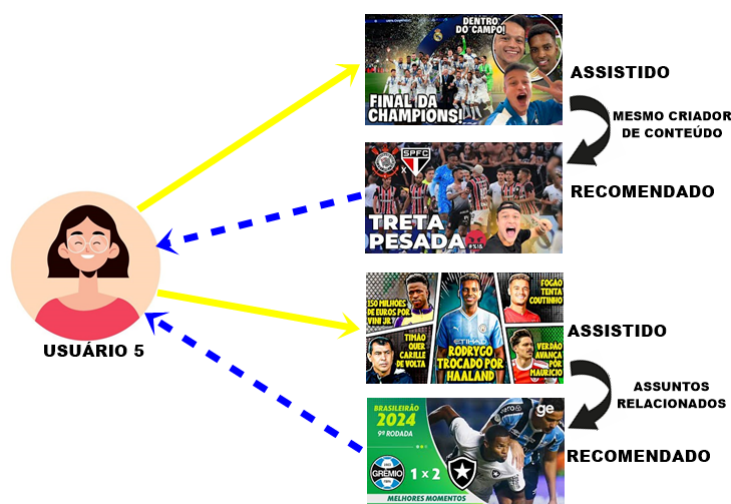
Na Figura 4, o usuário assistiu a um vídeo do Gonze Neles, sendo então recomendado outro vídeo do mesmo canal. Além disso, o usuário também assistiu a um vídeo do canal Futirinhas que aborda alguns assuntos, dentre eles, o Botafogo, resultando na recomendação de um vídeo do GE com os melhores momentos do jogo entre Grêmio e Botafogo, válido pela 9ª rodada do Campeonato Brasileiro de 2024.

Figura 3 – Exemplo 1 da Filtragem Baseada em Conteúdo



Fonte: autoria própria (2024).

Figura 4 – Exemplo 2 da Filtragem Baseada em Conteúdo



Fonte: autoria própria (2024).

2.2 Conteúdo esportivo online

O YouTube permite inúmeros formatos de conteúdo, tendo como destaque os *vlogs* que se popularizaram no início da década de 2010, abrindo espaço para os primeiros criadores de conteúdo, que se tornaram cada vez mais profissionais (Ott, 2021). Esse novo formato une os telespectadores ao futebol, em razão de serem torcedores e fãs de futebol criando conteúdo.

Embora jornalistas conceituados entrem na plataforma, os *youtubers* conseguem conquistar o público de diversas formas — como linguagem coloquial, vídeos engraçados, entrevistas descontraídas, desafios entre amigos, jogadores e ex-jogadores —, além do *streaming*, em virtude de que alguns canais transmitem jogos gratuitos, como o canal CazéTV e o canal Goat.

Alguns programas de televisão já aderiram a mudança para o formato digital, como o Jogo Aberto, que transmite simultaneamente na TV aberta e no YouTube de forma gratuita. Com isso, o canal Bandeirantes atrai mais pessoas e engaja em ambas as partes, para contar com uma boa audiência (Ott, 2021).

2.2.1 Engajamento do usuário

O público consome não somente o meio tradicional, com programas esportivos e os 90 minutos de jogo, mas também outros assuntos, como pós-jogo e melhores momentos. Os fãs estão engajando-se de maneira ativa por meio de curtidas, comentários e compartilhamentos de vídeos (Petersen-Wagner; Ludvigsen, 2023).

Ludvigsen e Petersen-Wagner (2023) afirmam que a plataforma proporciona um espaço para que os torcedores se envolvam nas novas tecnologias implantadas no esporte, intensificando seu sentimento pelo esporte. Antes, as opiniões eram tratadas em bares,

estádios e em casa, lugares em que não oferecem facilidade para interação com os clubes e jogadores.

Não só os fãs, como também os atletas conseguem expressar suas opiniões por intermédio de entrevistas realizadas pelos *youtubers* e criando seus canais na plataforma. Um exemplo é o atleta Vinícius Júnior, que, mediante seu canal, com 2,2 milhões de inscritos, mostra sua vida pessoal e opina sobre alguns temas.

Após analisarem os canais das cinco ligas mais famosas do mundo — a Premier League Inglesa (Inglaterra), La Liga (Espanha), Bundesliga (Alemanha), Serie A (Itália) e Ligue 1 (França) —, Petersen-Wagner e Ludvigsen (2023) afirmaram que os vídeos mais recentes costumam ter as melhores métricas, como visualizações, curtidas e comentários, em função da escalabilidade da plataforma e à lógica de seu algoritmo.

2.2.2 Desafios e oportunidades na produção de conteúdo esportivo online

Um dos desafios enfrentados pela nova geração de mídias sociais é a força da TV aberta, que, mesmo após a consolidação do YouTube, continua influenciando pessoas ao redor do mundo por meio de seus programas exibidos diariamente (Petersen-Wagner; Ludvigsen, 2023). Jornalistas conceituados e ex-jogadores comentam sobre as partidas e notícias do mundo futebolístico.

Em virtude disso, há uma desigualdade entre os novos e antigos meios de comunicação, visto que ambos precisam conviver de maneira harmoniosa (Petersen-Wagner; Ludvigsen, 2023). Apesar disso, há um desequilíbrio de poder: o primeiro está em ascensão e consolidação devido ao avanço tecnológico, enquanto o segundo mantém grande força devido aos anos de confiabilidade e receitas altas.

Entretanto, com o crescimento da internet, os megaeventos, como as Olimpíadas, permitiram novas oportunidades com parceiros comerciais e patrocinadores, possibilitando que os fãs acompanhem e interajam com esses eventos de novas maneiras (Ludvigsen; Petersen-Wagner, 2023).

Além disso, servem como uma ponte para a distância e o tempo entre o local físico que o evento está sendo realizado e o público global (Ludvigsen; Petersen-Wagner, 2023), como na Copa do Mundo Masculina de 2022, a qual todos puderam assistir aos jogos de suas casas ou bares à tarde, mesmo alguns jogos sendo à noite.

Além do que foi relatado, a funcionalidade *Shorts* consegue obter muito engajamento, sendo uma forma mais prática para produção de conteúdo, visto que são vídeos curtos com duração máxima de 1 minuto. Ludvigsen e Petersen-Wagner (2023) levantaram dados das duas últimas Olimpíadas de Verão, comprovando que tanto Rio 2016 quanto Tóquio 2020 tiveram ótimos resultados.

Ainda que o maior beneficiário seja o YouTube, os criadores de conteúdos obtêm *feedback* instantâneo dos consumidores, permitindo-lhes montar estratégias com finalidade de melhorar as métricas e agradar o algoritmo de recomendação, para que assim ganhem

destaque na plataforma (Petersen-Wagner; Ludvigsen, 2023).

2.3 Evolução dos sistemas de recomendação e seu impacto no conteúdo esportivo

Os SRs passaram por diversas mudanças desde sua criação. Segundo Xu *et al.* (2024), esses algoritmos podem ser comparados a uma “caixa preta”: recebem várias características dos usuários como entrada e retornam uma lista ordenada de recomendações. O termo “caixa preta” indica que o processo interno não é transparente, embora produza recomendações precisas com base nas variáveis fornecidas.

Felfernig *et al.* (2024) afirmam que os sistemas de recomendação esportiva focam em sugerir conteúdos relacionados a esportes, como treinamento, atividades e informações de eventos, auxiliando as pessoas a encontrar vídeos alinhados com seus interesses e experiências relacionados ao esporte.

2.3.1 Evolução para personalização do conteúdo

Nos primeiros tempos das plataformas *online*, especialmente nas de compra, as pessoas precisavam seguir um passo a passo para encontrar os produtos desejados, filtrando-os por classificação ou palavras-chave. No entanto, com o avanço da Inteligência Artificial, os SRs passaram por uma grande evolução (Xu *et al.*, 2024). Segundo Xu *et al.* (2024), mesmo um crescimento de 1% no conteúdo recomendado pode resultar em um aumento significativo nas vendas.

Com o avanço dos SRs, várias melhorias foram implementadas. Embora a FC e a FBC tenham abordagens distintas, essas técnicas se complementam quando combinadas para formar a filtragem híbrida, aprimorando a precisão e o alcance das recomendações, além de estabelecer uma ligação mais sólida entre o conteúdo recomendado e os interesses de cada indivíduo (You, 2024).

Schrammel (2023) define os SRs como aqueles que geram sugestões de interesse para os usuários. O autor destaca que, para garantir uma boa performance, é essencial compreender as dúvidas apresentadas, incluindo as necessidades, objetivos e preferências das pessoas, permitindo a aplicação dos SRs em diversas áreas.

2.3.2 Impacto no consumo e produção de conteúdo esportivo

Com a expansão do uso do algoritmo, foram implementadas opções como curtir, comentar e compartilhar, que ajudam a calcular a relevância do conteúdo para o público, organizando as recomendações com base na sua relevância (Xu *et al.*, 2024). Embora seja um sistema relativamente simples, tanto as pessoas quanto os criadores de conteúdo recebem *feedback* sobre o consumo dos vídeos.

Esse *feedback* permite que os *youtubers* consigam alinhar seus vídeos com o desejo do seu público. Felfernig *et al.* (2024) destacam alguns tipos de conteúdo que atraem a atenção dos inscritos, como vídeos sobre táticas de equipes, jogadores e estratégias implementadas no futebol. O autor acrescenta que os vídeos se destacam pela capacidade de adaptar práticas específicas ao usuário, promovendo a melhoria do desempenho pessoal.

Eventos esportivos, como Olimpíadas e Copas do Mundo, beneficiam-se significativamente das filtragens. Por exemplo, um usuário que assiste a gols de um jogador famoso pode receber recomendações relacionadas a esse jogador, seus companheiros de equipe e atletas históricos. Ademais, os usuários podem personalizar o consumo de conteúdo sobre esses eventos, recebendo vídeos de notícias, melhores momentos e entrevistas (Felfernig *et al.*, 2024).

Este capítulo apresentou alguns conceitos fundamentais sobre SRs, associando-os ao contexto do futebol. Ao abordar a evolução e o impacto das recomendações, percebe-se a relevância das filtragens, que ajustam o conteúdo conforme os interesses dos usuários, influenciando o comportamento dos consumidores e as estratégias escolhidas pelos canais.

Para compreender melhor os conceitos sobre SRs, foi planejado o desenvolvimento de um protótipo contemplando as técnicas de FC e FBC. Essa abordagem híbrida visa simular um processo para recomendação de vídeos do YouTube.

3 METODOLOGIA

A metodologia adotada para atingir os objetivos propostos abrange revisão da literatura, coleta de dados, análise qualitativa e quantitativa, implementação de um protótipo de sistema de recomendação reduzido e um estudo de caso curto. Com essas etapas, pretende-se analisar, investigar e compreender os processos de recomendações de vídeos na plataforma do YouTube, por intermédio do tema futebol, além de mostrar sua influência na experiência dos usuários e produtores de conteúdo.

3.1 Tipo de pesquisa

Segundo Wazlawick (2020), uma pesquisa científica pode ser classificada com base em diversos critérios, e não necessariamente se restringe a um único tipo. Ele descreve que a classificação pode ser baseada na natureza, nos objetivos e nos procedimentos técnicos.

Este trabalho possui alguns dos aspectos descritos por Wazlawick (2020). Em relação à sua natureza, é uma pesquisa primária, pois busca gerar um novo conhecimento sobre o tema. Quanto aos objetivos, é classificado como pesquisa descritiva e explicativa, pois busca descrever e analisar os sistemas de recomendação nos vídeos de futebol.

Sobre procedimentos técnicos, o trabalho adota a abordagem de métodos mistos, conforme definido por Gil (2017). O autor define a pesquisa de métodos mistos como aquela em que o investigador coleta e analisa dados utilizando as abordagens qualitativas e quantitativas em um único estudo. Essa combinação permite uma análise mais abrangente dos dados estudados.

Ademais, convém mencionar o *Design Science Research* (DSR), que visa esclarecer problemas em contextos específicos e criar novos conhecimentos científicos (Pimentel; Filippo; Santoro, 2020). A escolha do DSR para este estudo se justifica pela criação de um protótipo de sistema de recomendação. De modo geral, o DSR orienta a construção e avaliação de artefatos, como protótipos de SRs.

3.2 Revisão da literatura

A revisão da literatura concentrou-se em dois aspectos principais: os modelos tradicionais de recomendação (FC e FBC), e as particularidades de sistemas de recomendação em plataformas de vídeo como o YouTube. Foram considerados estudos anteriores sobre algoritmos de recomendação e sobre como eles são aplicados a contextos de nicho, como conteúdo esportivo, para fornecer uma base sólida para a implementação do protótipo. A partir desta revisão, foi possível escrever o Capítulo 2 deste documento, além de embasar a construção do protótipo.

3.3 Coleta de dados

A coleta de dados foi realizada utilizando o *Social Blade*, uma ferramenta *online* gratuita que permite obter estatísticas detalhadas, como números de inscritos, visualizações e gráfico de crescimento ao longo do tempo. As métricas de engajamento, curtidas e comentários foram coletadas manualmente diretamente da plataforma do YouTube.

Para isso, foram selecionados três tipos de vídeos de cada canal: o mais recente, o mais visualizado e o mais antigo, utilizando o filtro disponibilizado pelo Youtube. Essa estratégia possibilita uma amostra específica de diferentes fases de cada canal. Em seguida, foram coletadas as métricas de curtidas e comentários. Com essas informações, foi calculada a média de curtidas e comentários para cada canal. Essa análise visou compreender o engajamento dos usuários.

Para a seleção dos canais de futebol, os critérios de popularidade e relevância foram escolhidos com a intenção de garantir uma amostra diversificada, abrangendo diferentes perfis de público e estilos de conteúdo. A escolha criteriosa dos canais permite uma melhor compreensão das preferências dos usuários.

A popularidade, medida pelo número de inscritos e visualizações, permite incluir canais com altos índices de alcance e influência, revelando padrões de engajamento e oferecendo informações sobre as preferências de um público amplo. Já a relevância busca capturar canais que, mesmo com audiências menores, possuem um tema consolidado e seguidores engajados, proporcionando uma visão mais detalhada do consumo de conteúdo esportivo.

3.3.1 Armazenamento dos dados

Os dados obtidos foram organizados em uma base de dados utilizando o Google Planilhas, uma ferramenta que permite uma fácil administração das informações. Para garantir uma estrutura clara e acessível, as colunas foram preparadas com nome dos canais, tipo de conteúdo, número de visualizações, número de inscritos, curtidas e comentários.

Cada coluna tem um papel específico na análise dos dados. O nome dos canais serve para identificar os canais selecionados e a fonte dos dados, enquanto o tipo de conteúdo permite observar a variedade de vídeos analisados. O número de visualizações e inscritos fornece uma medida de popularidade e alcance dos canais. As métricas de curtidas e comentários são essenciais para avaliar o engajamento do público nos vídeos.

3.3.2 Análise qualitativa e quantitativa

A análise qualitativa buscou identificar padrões, temas e tendências relacionados à recomendação de vídeos de futebol, por meio da interpretação das visualizações dos usuários. A época em que os vídeos foram feitos é um fator a ser considerado, permitindo uma compreensão do que motiva a interação com os vídeos.

Por outro lado, a análise quantitativa envolveu a coleta, a análise e o cálculo de métricas relevantes, como curtidas, comentários e o crescimento das visualizações e inscrições ao longo do tempo. Essa abordagem possibilitou entender melhor o comportamento dos vídeos no YouTube, revelando tendências de popularidade e engajamento que complementam as percepções obtidas na análise qualitativa.

3.4 Protótipo de sistema de recomendação

Um protótipo reduzido de sistema de recomendação foi desenvolvido utilizando técnicas de FC e FBC. A FC recomenda vídeos com base no comportamento e nas preferências de usuários com perfis semelhantes, enquanto a FBC sugere vídeos com base no histórico de consumo do próprio usuário.

O processo de desenvolvimento do protótipo foi conduzido pela revisão dos artigos e pelas observações obtidas na análise dos gráficos de desempenho dos canais. Essas análises ajudaram a definir as funcionalidades e abordagens que o protótipo deveria conter.

O protótipo foi desenvolvido em *Python*, utilizando a biblioteca *Sklearn*, para calcular a similaridade entre usuários e itens, e a biblioteca *NumPy*, para manipular *arrays* e operações matemáticas. Inicialmente, foram criados perfis simplificados de usuários e vídeos, seguidos pela construção de uma matriz de interações, que representa vídeos assistidos por cada usuário.

Com a combinação dessas abordagens foram fornecidas recomendações personalizadas. O protótipo demonstrou a funcionalidade básica do sistema, simulando o processo de recomendação de vídeos. Foram utilizados dados simulados no protótipo.

O uso de dados simulados no protótipo justifica-se por algumas limitações, incluindo o acesso restrito à API do YouTube e o custo associado à coleta de dados. Embora dados reais pudessem proporcionar uma análise mais precisa e relevante, os dados simulados possibilitaram a implementação do protótipo dentro dos recursos e prazos disponíveis.

Esses dados hipotéticos foram elaborados para representar as interações de usuários com vídeos, permitindo a demonstração das funcionalidades principais do sistema. Apesar de não capturarem integralmente a complexidade das interações reais, esses dados exercem uma função representativa, oferecendo uma visão próxima do processo de recomendação.

3.5 Breve estudo de caso

Este estudo de caso visou analisar como as recomendações influenciam a experiência dos usuários e criadores de conteúdo no tema futebol. Para isso, os dados do protótipo foram utilizados para avaliar seu funcionamento, considerando tanto a interação dos usuários quanto as características dos vídeos recomendados.

Foram realizados testes simples, com perfis simulados de usuários e vídeos, com o objetivo de analisar o protótipo do sistema de recomendação desenvolvido. É importante enfatizar que os dados utilizados são fictícios e servem para ilustrar o comportamento das pessoas e a performance dos vídeos.

Esse estudo de caso é relevante para demonstrar a aplicabilidade da teoria relacionada aos sistemas de recomendação, bem como seu potencial para aprimorar a experiência de consumo e criação de conteúdo. Ao analisar os resultados, é possível observar de maneira clara como os SRs funcionam.

Este capítulo apresentou os aspectos metodológicos deste trabalho de conclusão de curso — envolvendo a coleta e armazenamento de dados, análise qualitativa e quantitativa, e implementação de um protótipo de um sistema de recomendação —, que se relacionam ao objetivo geral e aos objetivos específicos definidos na Seção 1.3.

4 RESULTADOS E DISCUSSÃO

Ao longo deste capítulo, são apresentados e analisados os dados coletados. Para atender aos objetivos do estudo, foram coletados dados qualitativos (nome do canal e título do vídeo) e quantitativos (visualizações, curtidas, número de inscritos e taxa de crescimento) que oferecem uma visão integrada sobre o desempenho e engajamento dos canais de futebol no YouTube. Além disso, é descrito o protótipo implementado, seguido do breve estudo de caso realizado.

4.1 Avaliação referente aos Canais

Nesta seção, são apresentados os dados coletados dos canais — como nome do canal, tipo de conteúdo, número de visualizações, número de inscritos, curtidas e comentários —, bem como uma avaliação dos gráficos de crescimento fornecidos pelo site *Social Blade*, permitindo uma compreensão mais detalhada sobre o desempenho e a popularidade de cada canal.

4.1.1 Dados coletados

No Quadro 1, são apresentados os dados coletados no dia 21 de agosto de 2024, com a análise de 13 canais, categorizados conforme critérios de tipo de conteúdo e formato de publicação (vídeo, *stream*, televisão), possibilitando uma análise comparativa entre diferentes estilos de conteúdo. Entre os canais, é possível destacar o canal Jogo Aberto com 4,85 milhões de inscritos e o canal Gol de Canela que possui 295 mil inscritos. Esses dados servem para ilustrar a diversidade de canais e mostrar como as recomendações variam em função do alcance dos canais, tanto de grande como de pequeno porte.

Quadro 1 – Canais coletados

Canais	Tipo de Conteúdo	Número de Visualizações	Inscrições	Curtidas	Comentários
Canal Goat	Stream	330.660.721	3.56M	Média de 75.023	Média de 53
CazéTV	Stream	1.998.497.825	16.2M	Média de 329.000	Média de 164
ESPN Brasil	V, S e TV	4.101.952.073	6.26M	Média de 102.347 / 10.630	Média de 5.611 / 234
Jogo Aberto	V, S e TV	2.138.352.787	4.85M	Média de 53.135 / 40.667	Média de 1.166,67 / 566,67
TNT Sports Brasil	V, S e TV	2.982.808.175	11.1M	Média de 220.892 / 48.733	Média de 15.302 / 481,33
Confederação Brasileira de Futebol	Vídeo e Stream	237.160.477	1.72M	Média de 39.876 / 20.476	Média de 3.122 / 291,33
GE	Vídeo e Stream	2.908.603.037	5.08M	Média de 72.086 / 16.541	Média de 3.309,33 / 90,67
Desimpedidos	Vídeos	2.265.103.977	9.88M	Média de 4.900	Média de 11.230,33
Futebol pelo Mundo	Vídeos	49.388.838	572K	Média de 13.800	Média de 1.582,33
Futirinhas	Vídeos	606.428.906	2.09M	Média de 45.067	Média de 369,33
Gol de Canela	Vídeos	62.365.613	295K	Média de 20.000	Média de 651,67
Gonze Neles	Vídeos	464.200.491	1.61M	Média de 118.600	Média de 1.960,33
Modo Carreira Soto	Vídeos	278.330.026	2.31M	Média de 67.000	Média de 2.499

Fonte: autoria própria (2024).

Conforme apresentado no Quadro 1, na categoria “*Stream*”, foram selecionados dois canais: CazéTV e Canal Goat. Em seguida, na categoria “*Vídeo, Stream e Televisão*”,

estão os canais ESPN Brasil, Jogo Aberto e TNT Sports Brasil, que oferecem tanto vídeos quanto transmissões ao vivo na plataforma, sem deixar de lado a televisão.

Após isso, há a Confederação Brasileira de Futebol (CBF) e o GE, que se encaixam na categoria “Vídeo e *Stream*” por oferecerem tanto vídeos quanto transmissões ao vivo. Por fim, na categoria “Vídeos”, há seis canais: Desimpedidos, Futebol pelo Mundo, Futirinhas, Gol de Canela, Gonze Neles e Modo Carreira Soto, que produzem exclusivamente conteúdo em vídeos.

Para calcular a média das métricas de curtidas e comentários, foram selecionados três vídeos: o mais recente, o mais visualizado e o mais antigo. Para os canais que oferecem tanto vídeos quanto *streams*, foram realizadas duas médias, uma para os vídeos e outra para os *streams*.

Por exemplo, no canal GE, os vídeos têm média de 72.086 curtidas, enquanto os *streams* possuem uma média de 16.541. Quanto aos comentários, a média é de 3.309,33 nos vídeos e 90,67 nos *streams*. Embora alguns canais incluam conteúdo televisivo, esta pesquisa se concentra nos dados disponíveis no YouTube.

Os dados revelam que, mesmo com um número alto de inscritos, as visualizações podem ser maiores em canais menores. Ao analisar os dois canais com menor número de inscritos, essa afirmação se torna evidente. O canal Futebol pelo Mundo possui 575 mil inscritos e alcançou 49.388.838 visualizações, enquanto o canal Gol de Canela, que conta com 295 mil inscritos, cerca de 280 mil a menos, acumula 62.365.613 visualizações. Essa diferença de 12.976.775 visualizações mostra que, embora o canal tenha menos inscritos, um conteúdo atrativo pode resultar em um maior número de visualizações.

Isso sugere que fatores como conteúdo exclusivo e estilo atraente impactam o engajamento de maneira significativa, independente do tamanho da base de inscritos.

4.1.2 *Análise dos canais*


O aspecto tratado no final da subseção anterior (canais com menor número de inscritos superando, em visualizações, canais maiores) sugere que fatores como conteúdo exclusivo e estilo atraente impactam o engajamento de maneira significativa, independente do tamanho da base de inscritos.

A análise dos dados de visualizações e crescimento e inscritos em diversos canais de futebol no YouTube revela padrões específicos que variam de acordo com os eventos esportivos e as estratégias adotadas pelos criadores de conteúdo, ocorrendo um aumento, diminuição e estabilização em ambos os parâmetros.

O crescimento dos canais estão associados aos grandes eventos esportivos, como Copa do Mundo, Olimpíadas, campeonatos nacionais e internacionais. Alguns canais acompanharam essa tendência e conseguiram alavancar seus números. A pesquisa analisou os gráficos no intervalo entre junho de 2023 a junho de 2024.

O canal **Goat** apresentou um crescimento significativo ao adquirir os direitos de transmissão de campeonatos estaduais e do Campeonato Saudita. Esse aumento é evidenciado no gráfico da Figura 5, que mostra um desempenho positivo no início desses eventos.


Figura 5 – Gráfico de Crescimento ao longo do tempo do canal Goat



Fonte: adaptado de Social Blade (2024a)

O canal **CazéTV** aplicou estratégia similar, adquirindo os direitos da Copa do Mundo Feminina, Campeonato Paulista e Olimpíadas. Ao analisar o gráfico da Figura 6, é possível perceber que, na época dessas transmissões, o canal obteve bons números. Embora as Olimpíadas não sejam um evento exclusivo de futebol, ao analisar o canal em sua página do YouTube, percebe-se que a transmissão mais assistida foi a final do futebol feminino entre Brasil e Estados Unidos.


Figura 6 – Gráfico de Crescimento ao longo do tempo do canal CazéTV



Fonte: adaptado de Social Blade (2024b)

O canal **ESPN Brasil**, que não transmite os jogos, utiliza trechos das partidas de futebol para publicar vídeos — como os melhores momentos de uma partida e lances que chamam a atenção das pessoas —, teve oscilações consideráveis, conforme apresentado na Figura 7. Esse comportamento pode ser atribuído a suas transmissões com opiniões de ex-jogadores e jornalistas sobre diversos assuntos atuais do futebol.


Figura 7 – Gráfico de Crescimento ao longo do tempo do canal ESPN Brasil



Fonte: adaptado de Social Blade (2024e)

O canal **TNT Sports Brasil** segue o mesmo caminho do anterior, posta vídeos de jogos no qual tem direitos, mas com um diferencial: transmitir jogos com narração, sem imagens. O gráfico da Figura 8 indica que os inscritos se mantêm engajados, assistindo tanto aos jogos quanto às análises dos apresentadores.

Figura 8 – Gráfico de Crescimento ao longo do tempo do canal TNT Sports Brasil




Fonte: adaptado de Social Blade (2024m)

O canal **GE**, parte do Grupo Globo, beneficia-se ao realizar a cobertura de diversos eventos. Embora não transmita os jogos, aproveita esses eventos para exibir imagens antes de partidas e resumos dos jogos.

Estratégias como recortes de programas televisivos e entrevistas com personalidades do futebol contribuem para uma presença contínua na plataforma, atraindo não apenas fãs de futebol, mas também espectadores interessados em análise e debate esportivo, como exemplificado pelo canal GE. Assim como a CazéTV, o GE atingiu métricas altas durante as Olimpíadas, como ilustrado na Figura 9.

Figura 9 – Gráfico de Crescimento ao longo do tempo do canal GE




Fonte: adaptado de Social Blade (2024h)

Apesar de ser um canal menor em comparação aos citados, o **canal Gonze Neles** colheu frutos de alguns eventos. Com um conteúdo diferente, o *youtuber* tenta aproximar os torcedores com os jogos de futebol, gravando um resumo de jogos do Campeonato Brasileiro, Copa América, *Champions League*, dentre outros torneios.

Apesar de não publicar vídeos sobre as Olimpíadas, seu canal alcançou bons resultados, conforme apresentado na Figura 10. É provável que os vídeos relacionados à Copa América e à entrevista com Neymar Jr., atleta de renome mundial, tenham contribuído para alcançar essas estatísticas favoráveis.


Figura 10 – Gráfico de Crescimento ao longo do tempo do canal Gonze Neles



Fonte: adaptado de Social Blade (2024j)

Como apresentado na Figura 11, o **canal Jogo Aberto** foi o mais estável durante o período analisado, com variações mínimas. As oscilações nas visualizações são praticamente imperceptíveis. Mesmo diante de eventos relevantes, os números de visualizações e inscritos não sofreram grandes alterações.


Figura 11 – Gráfico de Crescimento ao longo do tempo do canal Jogo Aberto



Fonte: adaptado de Social Blade (2024k)

Por outro lado, há o **canal Desimpedidos** que, no início do período analisado, estava em baixa. No entanto, com o acordo feito com a Rede Globo, o canal captou um aumento significativo, mas estabilizou posteriormente. Na Figura 12, são visíveis as oscilações no ganho de inscritos, devido a alguns fatores, como a Copa Desimpedidos e a saída de integrantes importantes.


Figura 12 – Gráfico de Crescimento ao longo do tempo do canal Desimpedidos



Fonte: adaptado de Social Blade (2024d)

O canal CBF atraiu uma grande audiência devido às transmissões ao vivo de sorteios de competições nacionais, que definem os confrontos entre as equipes, e às coletivas de imprensa da seleção brasileira, o que resultou em variações nas visualizações e no número de inscritos, como apresentado na Figura 13.

Figura 13 – Gráfico de Crescimento ao longo do tempo do canal Confederação Brasileira de Futebol




Fonte: adaptado de Social Blade (2024c)

De acordo com a Figura 14, o **canal Gol de Canela**, focado em explorar curiosidades do universo do futebol, apresentou instabilidade ao longo do período examinado. Ao analisar o canal, nota-se a falta de uma frequência de postagens, em contraste com outros canais que postam diariamente.

Embora a ausência de postagens diárias não seja um obstáculo, uma vez que canais como o Desimpedidos também não seguem esse padrão, estes conseguem manter uma base de público engajada e fiel. Por outro lado, o Gol de Canela, apesar de contar com um número de inscritos menor, tem alcançado bons resultados.

Figura 14 – Gráfico de Crescimento ao longo do tempo do canal Gol de Canela




Fonte: adaptado de Social Blade (2024i)

Ao analisar o gráfico da Figura 15, é possível observar que o **canal Futebol pelo Mundo** variou em alguns momentos. Com o conteúdo bastante similar ao do canal Gonze Neles, mostrando os jogos locais e alguns internacionais, enfrentou dificuldades em não conseguir produzir vídeos em eventos de grande porte, como a Copa América.

Apesar disso, conseguiu vídeos exclusivos de jogos em alguns países pelo mundo, como Polônia (um campeonato muito desconhecido do público brasileiro) e Alemanha. Conteúdos como esse ajudam no engajamento, além de adquirir um novo público para o canal.

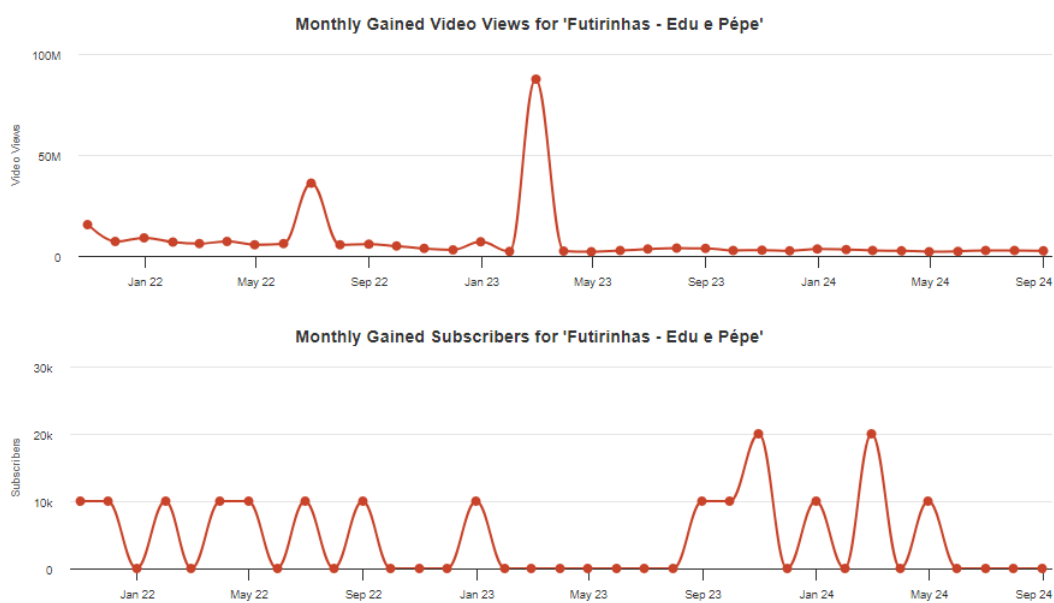
Figura 15 – Gráfico de Crescimento ao longo do tempo do canal Futebol pelo Mundo



Fonte: adaptado de Social Blade (2024f)

Por sua vez, o canal **Futirinhas** manteve-se estável com um desempenho positivo, como pode ser visto na Figura 16. As visualizações exigem um grau elevado de performance, com uma expectativa de mais de 20 milhões de *views* por mês, considerando que, antes do período analisado, o canal registrou picos superiores a 20 milhões.

Figura 16 – Gráfico de Crescimento ao longo do tempo do canal Futirinhas

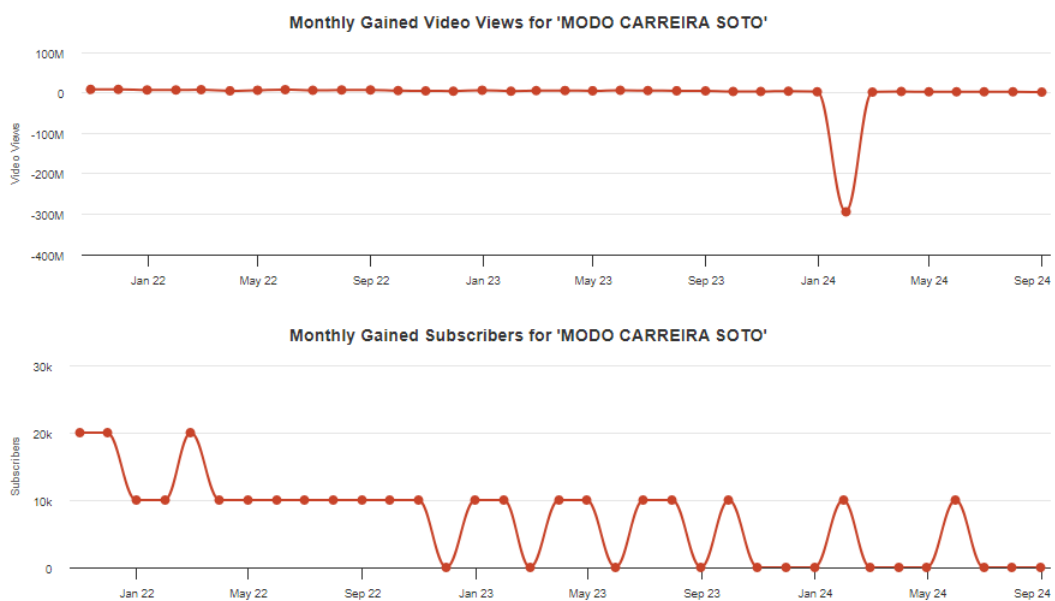


Fonte: adaptado de Social Blade (2024g)

Em contrapartida, o **canal Modo Carreira Soto** ganhou poucos inscritos, mas alcançou boas estatísticas de *views*, sempre acima de 2 milhões. No entanto, no mês de janeiro o gráfico apresentado na Figura 17 mostra que houve uma queda significativa, atingindo números extremamente negativos.

Essa drástica queda pode ter sido ocasionada pela exclusão de vídeos por parte do criador de conteúdo. Duas possibilidades podem ter levado a essa ação: a violação dos direitos autorais da plataforma e reações negativas a opiniões expressas sobre os assuntos abordados em certos vídeos, por parte dos espectadores e pessoas envolvidas.

Figura 17 – Gráfico de Crescimento ao longo do tempo do canal Modo Carreira Soto



Fonte: adaptado de Social Blade (2024l)

A análise dos gráficos das páginas anteriores revela uma correlação entre grandes eventos esportivos (como Copa do Mundo e Olimpíadas) e picos de crescimento de inscritos e visualizações em determinados canais. Esse comportamento sugere que a demanda por conteúdo esportivo se intensifica durante grandes competições, beneficiando os canais que transmitem e comentam esses eventos. Isso reforça a importância de uma cobertura em tempo real para alavancar o engajamento.

Em períodos sem grandes momentos esportivos ou quando há ausência de exibição de eventos, as métricas de inscritos e visualizações tendem a estabilizar ou declinar. Um exemplo disso é o canal ESPN Brasil, que não conseguiu manter bons números durante as Olimpíadas, assim como o canal Futebol pelo Mundo, que apresentou um desempenho semelhante.

Em paralelo, os canais Gonze Neles e CazéTV conseguiram resultados positivos. Este transmitiu tudo das Olimpíadas, enquanto o primeiro se reinventou com conteúdos exclusivos e cobriu a Copa América, de forma que atraiu todos os públicos.

Essa análise também sugere que as escolhas de conteúdo no YouTube podem ser influenciadas por algoritmos de recomendação que aplicam as técnicas de FC e FBC. Para os amantes de futebol, assistir a competições de alto nível é uma experiência altamente satisfatória. Os canais que estavam correlacionados ganharam bastante destaque, como o GE e o Gonze Neles, ambos postando conteúdos relacionados à Copa América e ao Campeonato Brasileiro; simultaneamente, a CazéTV transmitia as Olimpíadas.

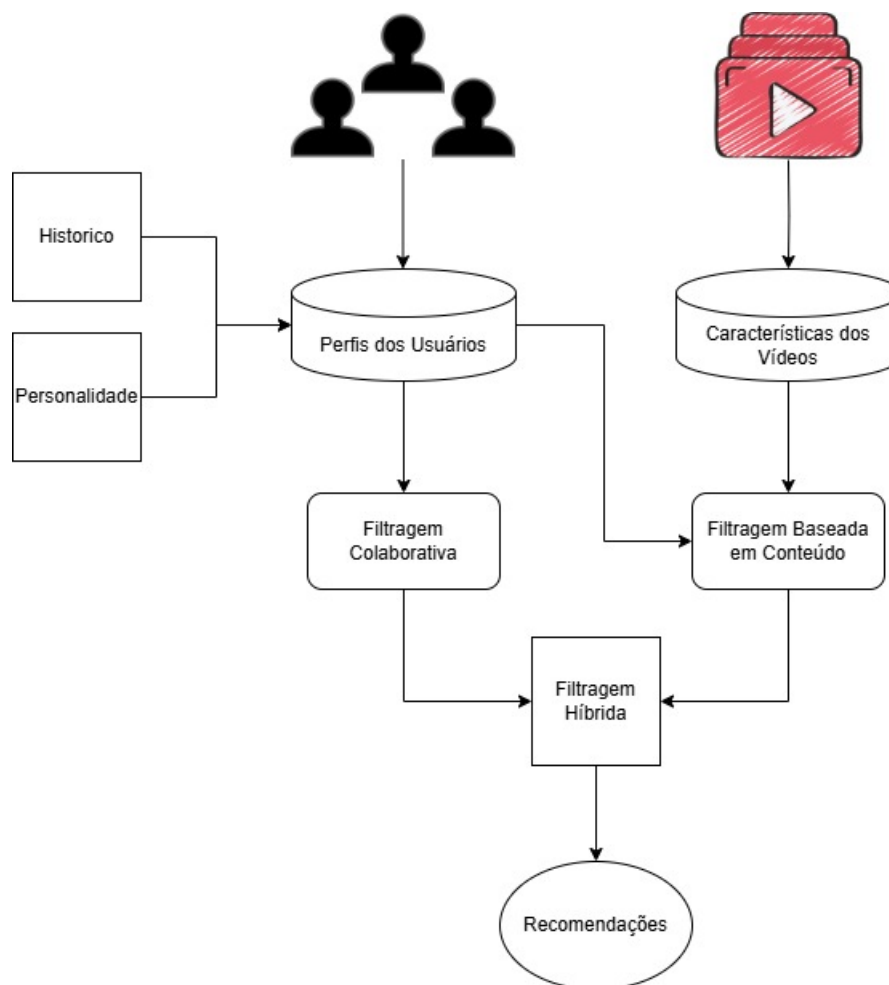
Nesse exemplo básico, é possível compreender como as filtragens se comportam. A FC, por exemplo, poderia sugerir vídeos tanto da CazéTV quanto do Gonze Neles, uma vez que ambos compartilham uma conexão com o canal GE. Por sua vez, a FBC, com base nas preferências de conteúdo, poderia recomendar vídeos de outras competições que os canais postam.

Essa análise demonstra de forma simplificada que o sucesso dos canais esportivos no YouTube não depende apenas de transmissões de jogos, mas também de uma diversificação de conteúdo — desde entrevistas até vídeos descontraídos e engraçados — e da aplicação de estratégias de engajamento durante eventos de temporada. Esses achados estão alinhados aos objetivos do estudo, que visa identificar os fatores que impulsionam o sucesso dos canais de futebol na plataforma.

4.2 Implementação do protótipo e breve estudo de caso

Nesta seção, são apresentados aspectos de um protótipo simples de sistema de recomendação personalizado, desenvolvido para sugerir conteúdos futebolísticos relevantes aos usuários. O protótipo emprega FC e FBC, considerando perfis de usuários e características dos vídeos para gerar recomendações ajustadas com base nas interações e preferências individuais. Na Figura 18, é ilustrado o diagrama do protótipo desenvolvido, indicando seus componentes. No Apêndice A, encontra-se o código em *Python* para o protótipo.

Figura 18 – Diagrama do protótipo



Fonte: autoria própria (2024).

4.2.1 Bibliotecas importadas

A biblioteca *NumPy* é amplamente utilizada para manipulação de *arrays* e operações matemáticas em *Python*, fundamental para lidar com grandes volumes de dados de maneira rápida e otimizada. Além disso, foi utilizada a função *cosine similarity* da biblioteca *Sklearn*, uma ferramenta usada em aprendizado de máquina e análise de dados.

A função é aplicada para calcular a similaridade entre vetores em espaço de alta dimensão. Nesse contexto, é útil para identificar usuários ou vídeos semelhantes com base em características conectadas, como o histórico de interações ou conteúdo similar.

4.2.2 Criação dos perfis de usuários e vídeos

Foram definidos perfis de usuários e vídeos, armazenados respectivamente em dois dicionários chamados “*users*” e “*videos*”. Cada usuário é identificado por um número, e cada perfil contém características pessoais e preferências específicas de consumo de vídeos.

Os atributos foram escolhidos para representar diferentes estilos e comportamen-

tos¹ dos indivíduos. Características como “extroversão” e “curiosidade” indicam a sociabilidade e interesse em explorar novas informações. Foi definida uma escala de 1 a 5 para representar a intensidade dessas características, em que 1 representa um perfil introvertido e pouco curioso, e 5 retrata uma personalidade bastante extrovertida e muito curiosa.

Para completar o perfil dos usuários, foram incluídas preferências de consumo de vídeos. A linguagem “visual” indica uma preferência por conteúdo com imagens e vídeos, enquanto a “verbal” pela fala. Também foram consideradas preferências por vídeos “práticos” (que são dinâmicos e interativos) e “analíticos” (voltados para a análise de tudo que envolve o futebol). Para indicar a presença ou ausência dessas características, foram atribuídos valores binários, 0 e 1.

Em relação às características (“perfis”) dos vídeos, os tipos de conteúdo selecionados foram: “*highlight*” (destaques ou melhores momentos), “análise” (comentários técnicos, táticos e de jogadores) e “entrevista” (conversas com jogadores, treinadores, especialistas ou dirigentes). Esses atributos são representados por valores binários, indicando o tipo de conteúdo do vídeo.

Para concluir o perfil de vídeos, configurou-se a “duração” (medida em minutos, para permitir diferenciar vídeos longos e curtos) e o tipo de linguagem predominante: “visual”, “verbal” ou ambos.

Essas características foram escolhidas para contemplar diferentes tipos de personalidade e tipos de conteúdo, visando personalizar as recomendações do sistema. A estrutura dos perfis de usuários e vídeos permite identificar padrões de comportamento e preferências específicas, ajustando as recomendações para torná-las mais precisas e relevantes para os usuários.

Por exemplo, pessoas que preferem elementos visuais ou verbais e curtos podem receber vídeos de “*highlight*”, enquanto aqueles que preferem conteúdos práticos são guiados para vídeos com essa característica.

4.2.3 Histórico de interações

Foi criada uma matriz de interação para representar as preferências dos usuários em relação aos vídeos disponíveis no sistema. Esta matriz foi estruturada utilizando a biblioteca *NumPy*, permitindo a manipulação eficiente dos dados em formato de *array*. As linhas da matriz representam os usuários, enquanto as colunas equivalem aos vídeos, com cada célula indicando a interação com os vídeos.

Cada interação dos usuários com os vídeos é representada por números binários. O número 1 indica que interagiu com o vídeo, assistindo, marcando como gostei, comentando ou compartilhando, e o número 0 revela que não houve interação.

¹ Traços de personalidade e estilos de aprendizagem podem influenciar as preferências dos usuários e, portanto, serem aproveitados em SRs (Aguiar; Araujo; Costa, 2022).

Essa matriz permite ao sistema analisar as interações entre os usuários e os vídeos, identificando padrões de consumo e preferências. Com base na matriz é possível aplicar as técnicas de recomendação. Por exemplo, se um usuário interage frequentemente com vídeos de análise, o sistema priorizará esse tipo de conteúdo em recomendações futuras, atendendo assim às necessidades deste usuário.

4.2.4 Funções para recomendação por filtragem colaborativa e baseada em conteúdo

Foram implementadas duas funções em *Python* para a recomendação de vídeos, uma baseada em FC e outra em FBC. Essas abordagens são usadas para sugerir vídeos relevantes aos usuários, considerando suas preferências e interações, bem como os padrões de consumo de outros usuários.

A função de recomendação por FC utiliza a matriz de interação com os vídeos. Primeiramente, a similaridade entre os usuários é calculada pela função *cosine similarity*, que mede o grau de semelhança nos padrões de interação. Em seguida, são extraídas as pontuações de similaridade do usuário em relação aos demais, identificando o consumo similar entre as pessoas.

Com base nessas pontuações, a função calcula uma pontuação ponderada para cada vídeo, atribuindo maior peso aos vídeos populares entre usuários com interesses semelhantes. A função então filtra os vídeos aos quais o usuário assistiu, recomendando apenas os que ainda não foram assistidos, sendo ordenados com base nas pontuações ponderadas, de forma que os mais relevantes sejam selecionados para a recomendação.

A FBC, por outro lado, começa com a extração dos atributos do usuário alvo, formando um perfil que inclua suas preferências específicas de consumo de conteúdo. Em paralelo, os atributos dos vídeos são reunidos em uma matriz contendo suas características exclusivas.

A similaridade entre o perfil do usuário e dos vídeos é calculada utilizando novamente a função *cosine similarity*, determinando o alinhamento entre os interesses do usuário com os vídeos disponíveis. Logo após, os vídeos são ordenados com base no grau de similaridade e os mais importantes são escolhidos.

Essas técnicas, ao combinarem diferentes abordagens de recomendação, melhoram a precisão do sistema, proporcionando recomendações que atendem tanto os interesses individuais quanto a criação de conteúdo, que produzem de acordo com a tendência entre os usuários.

4.2.5 Função híbrida

Foi implementada uma função em *Python* para a recomendação híbrida, que combina as funções de FC e FBC, com o objetivo de melhorar a precisão das recomendações, considerando tanto os interesses individuais quanto as similaridades com outros usuários.

A função permite combinar as forças de ambos, fornecendo recomendações mais personalizadas.

O processo começa obtendo as recomendações por meio das funções de FC e FBC, fornecendo uma lista de vídeos recomendados com base no cálculo realizado por cada uma. Para combinar os resultados, um dicionário é utilizado para armazenar as pontuações finais dos vídeos recomendados.

Cada recomendação pela FC recebe um peso padrão de 0,5 (ou seja, 50%), determinado pelo parâmetro *peso_fc*. Em seguida, são processados os dados obtidos pela FBC. Se um vídeo estiver presente no dicionário, a pontuação é incrementada para retratar a importância de ser recomendado por ambas as técnicas. Caso contrário, o vídeo é adicionado ao dicionário com a pontuação de $1 - \textit{peso_fc}$.

Por fim, os vídeos são ordenados com base nas pontuações finais, priorizando aqueles com maior relevância, e os vídeos com melhores classificações são armazenados no parâmetro *top_recomendacoes*, escolhidos para recomendação. Essa abordagem fornece, de forma equilibrada, diferentes aspectos do comportamento humano e características dos conteúdos, aumentando as chances de sugestões mais precisas e interessantes.

4.2.6 Gerar recomendação para cada usuário

As recomendações são geradas para os usuários utilizando a função híbrida. O código transita pela lista de usuários e, para cada um, aplica a recomendação híbrida, utilizando a matriz de interação, os dados dos usuários e as características dos vídeos. A função retorna uma lista com os vídeos mais significativos conforme a combinação das técnicas de recomendação.

A função gera até n vídeos para cada usuário, conforme especificado pelo parâmetro *top_recomendacoes*. As recomendações são convertidas para números inteiros para facilitar a apresentação dos resultados. Por fim, as sugestões são exibidas neste formato de saída: *Recomendações para o usuário X: Vídeo(s) A - B - C*.

4.2.7 Estudo de caso reduzido

Este estudo de caso visou avaliar simplificadaamente como as recomendações influenciam a experiência de consumo de conteúdo dos usuários e criadores, e no alcance dos vídeos de futebol. Para isso, o protótipo desenvolvido lidou com dados simulados para representar dez perfis fictícios de usuários e vídeos. Cada usuário foi identificado por um número de 1 a 10.

Foram realizados testes com esses perfis hipotéticos, que representam diferentes características de consumo, como características específicas dos vídeos, duração e estilo, além de personalidades variadas. Com esses dados, o sistema aplicou tanto a FC quanto a FBC para sugerir vídeos, buscando aumentar a relevância das sugestões.

A partir do que foi exposto na Seção 4.2.6, o ambiente virtual foi ativado no terminal, e o arquivo foi executado para fornecer as recomendações específicas para cada um dos dez usuários criados. Na Figura 19, são apresentadas as sugestões geradas pelo sistema. Os resultados mostram os vídeos recomendados ordenados por relevância, com base na aplicação do modelo híbrido.

Figura 19 – Vídeos recomendados para cada usuário

```
PS D:\Users\Arthur\Documents\UEPB\Período 2024.2\TCC II\Prototipo\prototipo-sistema-de-recomendacao> venv/Scripts/activate
(venv) PS D:\Users\Arthur\Documents\UEPB\Período 2024.2\TCC II\Prototipo\prototipo-sistema-de-recomendacao> python prot.py
Recomendações para o usuário 1: Vídeo(s) 10 - 5 - 6
Recomendações para o usuário 2: Vídeo(s) 7 - 6 - 9
Recomendações para o usuário 3: Vídeo(s) 8 - 10 - 9
Recomendações para o usuário 4: Vídeo(s) 7 - 5 - 3
Recomendações para o usuário 5: Vídeo(s) 3 - 6 - 9
Recomendações para o usuário 6: Vídeo(s) 7 - 5 - 10
Recomendações para o usuário 7: Vídeo(s) 5 - 8 - 2
Recomendações para o usuário 8: Vídeo(s) 6 - 10 - 3
Recomendações para o usuário 9: Vídeo(s) 8 - 6 - 9
Recomendações para o usuário 10: Vídeo(s) 9 - 10 - 3
```

Fonte: autoria própria (2024).

Cada linha apresenta as recomendações de cada pessoa, listando os três vídeos que se destacaram como os mais importantes para aquele usuário, segundo o algoritmo desenvolvido. Por exemplo, para o usuário 1 os vídeos recomendados foram 10, 5 e 6, enquanto para o usuário 6 os vídeos 7, 5 e 10 foram selecionados, indicando semelhanças nas sugestões para tais usuários.

Esses resultados permitem avaliar simplificada e a precisão e a variedade das recomendações fornecidas pelo sistema, verificando como o algoritmo atende às preferências e as necessidades dos usuários, considerando tanto as preferências pessoais quanto as tendências de consumo, gerando sugestões mais exatas e seguras.

Após a geração das recomendações dos usuários (Figura 19), nota-se que usuários com preferências por um conteúdo específico recebem recomendações de vídeos similares. Para mostrar a diversificação do conteúdo visualizado, há o usuário 10, que demonstrou preferência por vídeos de análise. Consequentemente, o sistema recomendou outro vídeo deste segmento. Contudo, também foram sugeridos dois vídeos da área de entrevista, visto que o usuário interagiu com esse tipo de conteúdo, levando a recomendação de um vídeo de outra categoria.

Por sua vez, o usuário 8, que prefere vídeos verbais, recebeu sugestões de vídeos visuais após interagir com alguns desse tipo, indicando uma adaptação nas recomendações. Esses resultados demonstram que o protótipo consegue distinguir os diferentes tipos de conteúdos e ajustar as sugestões com base no perfil e histórico de interação de cada usuário, destacando como o sistema consegue aprimorar a personalização para atender às necessidades dos usuários.

5 CONSIDERAÇÕES FINAIS

No capítulo atual, são apresentadas as considerações finais, visando sintetizar os principais resultados da pesquisa sobre a aplicação de sistemas de recomendação no contexto futebolístico. São discutidas as conclusões obtidas, as limitações do estudo e sugestões de trabalhos futuros.

5.1 Conclusões

Ao revisitar os objetivos específicos, percebe-se que a maioria foi atingida. O objetivo específico 1 — “Estudar as técnicas existentes de recomendação de itens, com enfoque no contexto de vídeos de futebol na plataforma do YouTube” — foi alcançado ao revisar a literatura sobre sistemas de recomendação, sendo apresentadas técnicas, de modo sintetizado, no Capítulo 2.

O objetivo específico 4 — “Desenvolver protótipo de sistema de recomendação para praticar os conceitos estudados e sugerir uma forma de recomendação de vídeos mais personalizada” — também foi atingido, com a implementação do protótipo reduzido, que abrange as técnicas de recomendação na Seção 4.2.

Entretanto, os objetivos específicos 2 e 3 — “Investigar como técnicas de recomendação podem aumentar o engajamento e a satisfação do público que consome vídeos de futebol” e “Compreender como a recomendação de vídeos de futebol influencia nas estratégias de produção de vídeos” — foram atendidos parcialmente.

Ao utilizar dados fictícios no protótipo, a investigação no estudo de caso ficou limitada. A compreensão nas estratégias de produção de vídeos se resumiu a uma discussão sobre ajustes nas estratégias com base nas recomendações e *feedback* dos usuários. Assim, o trabalho carece de uma análise mais aprofundada sobre o real impacto na decisão de produção de conteúdo.

O protótipo foi criado para a prática tanto dos princípios teóricos quanto práticos dos sistemas de recomendação, proporcionando uma compreensão de como as diferentes abordagens podem ser combinadas para oferecer recomendações personalizadas aos usuários de diferentes personalidades.

Ao revisitar a questão motivadora da pesquisa — “Como os sistemas de recomendação podem influenciar na experiência dos usuários no consumo de conteúdos relacionados ao futebol?” —, o trabalho responde, de maneira abrangente, que os SRs influenciam na experiência do usuário por meio de suas técnicas de filtragem. Essas técnicas permitem identificar e sugerir conteúdo mais alinhado às preferências individuais, otimizando o acesso a conteúdos relevantes e aprimorando o engajamento.

Por fim, o objetivo geral — “Explorar e estudar os processos de recomendação de vídeos de futebol, buscando entender como podem influenciar a experiência dos usuários e a criação de conteúdo” — foi alcançado em parte. O trabalho explorou alguns processos

de recomendação, fornecendo *insights* sobre a influência na experiência dos usuários e na criação de conteúdo pelos *youtubers*, além da dinâmica entre as recomendações, engajamento e estratégias de produção. Contudo, a compreensão limitou-se ao estudo de caso reduzido, necessitando de uma análise mais profunda sobre a influência na criação de vídeos.

Convém mencionar que este trabalho de conclusão de curso foi fundamental para reforçar conceitos obtidos ao longo do curso de bacharelado em Ciência da Computação, a exemplo de disciplinas de base, como Metodologia Científica, e disciplinas específicas, como Inteligência Artificial. Superar as dificuldades e desafios de um trabalho como este envolveu o uso de variadas habilidades, não apenas técnicas.

5.2 Limitações e sugestões para estudos futuros

Embora este estudo tenha fornecido percepções importantes sobre os sistemas de recomendação, algumas limitações foram identificadas. A coleta de dados foi restrita a um número limitado de canais, não representando a diversidade do conteúdo disponível no YouTube. Além disso, o uso de dados simulados no protótipo pode não reter completamente a complexidade das interações reais.

Outra limitação foi o tempo disponível para a execução deste trabalho, que restringiu o aprofundamento em certos pontos da pesquisa e limitou o nível de detalhamento da análise. Além disso, a falta de acesso à API do YouTube, devido ao custo elevado, dificultou a coleta de dados. Esses fatores juntos influenciaram a profundidade da análise e o alcance parcial de alguns objetivos específicos.

Como estudo futuro, sugere-se que o protótipo seja executável, com um código mais robusto, que permita o usuário interagir com o sistema. É pertinente também avaliar a eficácia das recomendações oferecidas pelo protótipo, utilizando critérios de sucesso e relevância percebida pelo usuário ou engajamento, a partir da análise de algumas métricas, como *f-measure* e taxa de cliques.

Ressalta-se que a escolha das bibliotecas *Sklearn* e *NumPy* foi adequada para o protótipo, mas essas bibliotecas podem não ser suficientes para SRs em grande escala. Em cenários reais, pode-se enfrentar problemas de escalabilidade, que exigiriam o uso de *frameworks* como *TensorFlow* ou *PyTorch*.

Além do uso desses *frameworks*, a implementação de redes neurais poderia aprimorar o sistema, permitindo personalizações em grande escala. Consequentemente, esse avanço tornaria as recomendações mais precisas, especialmente em plataformas com alta demanda de personalização. Esse aprimoramento poderia ser ainda mais eficaz se associando com uma interface gráfica, que facilitaria a interação do usuário com o sistema de recomendação e a avaliação de sugestões.

Assim como este trabalho considerou aspectos de personalidade, Felfernig *et al.* (2024) menciona a importância de considerar esses aspectos nos SRs. É observado também,

que essa integração entre a tomada de decisão humana e persuasão é rara na prática, e muitas abordagens atuais não consideram certas particularidades dos indivíduos para sugerir algo novo.

Incorporar características de personalidade dos usuários nos sistemas de recomendação é uma linha de pesquisa promissora (Dhelim *et al.*, 2022), mas não aprofundada neste trabalho. Uma sugestão para estudos futuros seria investigar como aspectos psicológicos (extroversão, etc.) podem influenciar a aceitação dos usuários e aumentar a precisão das recomendações no contexto do conteúdo futebolístico.

Vislumbra-se a possibilidade de a pesquisa contribuir não apenas para o meio acadêmico, mas também para os usuários, criadores de conteúdo e plataformas, que buscam encontrar vídeos alinhados com seus interesses e aumentar seu impacto no nicho de futebol, respectivamente.

Ao combinar o sistema com essas propostas de mudanças, o protótipo se transformaria em um projeto robusto, ajudando as pessoas interessadas a aprender como os sistemas de recomendação funcionam — não apenas pessoas ligadas ao futebol, como também em outras áreas de conteúdo no esporte e distintos.

Em síntese, para superar as limitações identificadas e aprimorar os sistemas de recomendação com foco específico na área do futebol, futuras pesquisas devem explorar a implementação de protótipos mais robustos e escaláveis, que possibilitem a interação em tempo real com os usuários e o uso de dados reais, permitindo uma análise mais precisa das recomendações.

A adoção de técnicas avançadas de aprendizado de máquina, como redes neurais profundas, pode ser essencial para aumentar a personalização e a precisão das sugestões, especialmente ao lidar com grandes volumes de dados. Além disso, uma investigação mais aprofundada sobre a influência das recomendações na produção de conteúdo, com base em métricas como engajamento e relevância percebida pelos criadores, pode contribuir para uma compreensão mais abrangente do impacto desses sistemas.

REFERÊNCIAS

- AGUIAR, J. J. B.; ARAUJO, J. M. F. R. d.; COSTA, E. d. B. **Estilos de Aprendizagem e Traços de Personalidade em Ambiente Educacional**: Análise com foco na educação em computação. Rio de Janeiro: e-Publicar, 2022. ISBN 978-65-5364-042-9. Disponível em: <https://doi.org/10.47402/ed.ep.b202212330429>. Acesso em: 29 de nov. de 2024.
- AGUIAR, J. J. B.; ARAUJO, J. M. F. R. de; COSTA, E. de B. Estudo comparativo de abordagens para sistemas de recomendação baseados em personalidade com uso do serviço IBM Watson Personality Insights. **Revista Ibérica de Sistemas e Tecnologias de Informação (RISTI)**, v. 40, p. 73–88, 2020. Disponível em: <https://doi.org/10.17013/risti.40.73-88>. Acesso em: 27 de maio de 2024.
- BLADE, S. **Canal GOAT's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/goatfutebolbr>. Acesso em: 21 de ago. de 2024.
- BLADE, S. **CazéTV's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: https://socialblade.com/youtube/c/caze_tv. Acesso em: 21 de ago. de 2024.
- BLADE, S. **Confederação Brasileira de Futebol's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/user/cbfselecao>. Acesso em: 21 de ago. de 2024.
- BLADE, S. **Desimpedidos's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/user/desimpedidos>. Acesso em: 21 de ago. de 2024.
- BLADE, S. **ESPN Brasil's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/espnbrasil>. Acesso em: 21 de ago. de 2024.
- BLADE, S. **Futebol pelo Mundo's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/futebolpelomundooficial>. Acesso em: 21 de ago. de 2024.
- BLADE, S. **Futirinhas - Edu e Pépe's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/futirinhas>. Acesso em: 21 de ago. de 2024.
- BLADE, S. **ge's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/geglobo>. Acesso em: 21 de ago. de 2024.
- BLADE, S. **Gol de Canela's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/goldecanela>. Acesso em: 21 de ago. de 2024.

BLADE, S. **Gonze Neles's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/gonzeneles>. Acesso em: 21 de ago. de 2024.

BLADE, S. **Jogo Aberto's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/jogoaberto>. Acesso em: 21 de ago. de 2024.

BLADE, S. **MODO CARREIRA SOTO's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/modocarreirasoto>. Acesso em: 21 de ago. de 2024.

BLADE, S. **TNT Sports Brasil's YouTube Stats (Summary Profile) - Social Blade Stats**. 2024. Disponível em: <https://socialblade.com/youtube/c/tntsportsbr>. Acesso em: 21 de ago. de 2024.

BOBADILLA, J. *et al.* Recommender systems survey. **Knowledge-Based Systems**, v. 46, p. 109–132, 2013. ISSN 0950-7051. Disponível em: <https://doi.org/10.1016/j.knosys.2013.03.012>. Acesso em: 27 de maio de 2024.

BRANDINI, E.; MACHADO, V.; MONTAGNER, B. T. **Do mundial ao Paulistão: entenda o sucesso de transmissões ao vivo de partidas de futebol no YouTube**. 2023. Disponível em: <https://www.thinkwithgoogle.com/intl/pt-br/estrategias-de-marketing/video/servicios-streaming-youtube-marketing/>. Acesso em: 28 de maio de 2024.

DHELIM, S. *et al.* A survey on personality-aware recommendation systems. **Artificial Intelligence Review**, v. 55, p. 2409–2454, 2022. Disponível em: <https://doi.org/10.1007/s10462-021-10063-7>. Acesso em: 29 de nov. de 2024.

EXAME. **CazéTV registra mais de 69 milhões de visualizações com jogos da Copa do Mundo Feminina 2023**. 2023. Disponível em: <https://exame.com/esporte/caze-tv-registra-mais-de-69-milhoes-de-visualizacoes-com-jogos-da-copa-do-mundo-feminina-2023/>. Acesso em: 28 de maio de 2024.

FELFERNIG, A. *et al.* Sports recommender systems: overview and research directions. **Journal of intelligent information systems**, v. 62, p. 1125–1164, 2024. Disponível em: <https://doi.org/10.1007/s10844-024-00857-w>. Acesso em: 27 de maio de 2024.

GIL, A. C. **Como elaborar projetos de pesquisa**. 6. ed. São Paulo: Atlas, 2017.

LUDVIGSEN, J. A. L.; PETERSEN-WAGNER, R. From television to youtube: digitalised sport mega-events in the platform society. **Leisure Studies**, Routledge, v. 42, n. 4, p. 615–632, 2023. Disponível em: <https://doi.org/10.1080/02614367.2022.2125557>. Acesso em: 21 de abr. de 2024.

MORESCHI, S.; MAJER, V. E. P. **YouTube Vibes: futebol para além dos 90 minutos da partida**. 2022. Disponível em: <https://www.thinkwithgoogle.com/intl/pt-br/estrategias-de-marketing/video/futebol-youtube-brasil-tendencia/>. Acesso em: 28 de maio de 2024.

MURATORI, P. **O que faz o YouTube ser tão essencial na vida das pessoas?** 2021. Disponível em: <https://www.thinkwithgoogle.com/intl/pt-br/tendencias-de-consumo/tendencias-de-comportamento/o-que-faz-o-youtube-ser-tao-essencial-na-vida-das-pessoas/>. Acesso em: 28 de maio de 2024.

OTT, L. G. **Jornalismo esportivo identificado e futebol no YouTube: um estudo de caso sobre os canais Vozes do Gigante e Fabiano Baldasso.** São Leopoldo: UNISINOS, 2021. Trabalho de Conclusão de Curso (Graduação em Jornalismo) — Universidade do Vale do Rio dos Sinos. Disponível em: <https://repositorio.jesuita.org.br/handle/UNISINOS/13053>. Acesso em: 12 de jun. de 2024.

PETERSEN-WAGNER, R.; LUDVIGSEN, J. A. L. Digital transformations in a platform society: A comparative analysis of european football leagues as youtube complementors. **Convergence**, v. 29, n. 5, p. 1330–1351, 2023. Disponível em: <https://doi.org/10.1177/13548565221132705>. Acesso em: 21 de abr. de 2024.

PIMENTEL, M.; FILIPPO, D.; SANTORO, F. M. Design science research: fazendo pesquisas científicas rigorosas atreladas ao desenvolvimento de artefatos computacionais projetados para a educação. *In*: JAQUES, P. A. *et al.* **Metodologia de Pesquisa Científica em Informática na Educação: Concepção de Pesquisa.** Porto Alegre: SBC, 2020, (Série Metodologia de Pesquisa em Informática na Educação, v. 1). Disponível em: <https://ceie.sbc.org.br/metodologia/index.php/livro-1/>. Acesso em: 29 de jun. de 2024.

QUIRINO, M. da C. **Aplicação prática de um sistema de recomendação utilizado em plataformas de streaming de vídeos.** Patos: UEPB, 2022. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) — Universidade Estadual da Paraíba. Disponível em: <http://dspace.bc.uepb.edu.br/jspui/handle/123456789/27661>. Acesso em: 28 de maio de 2024.

SANTOS, M. C. *et al.* Um sistema de recomendação baseado em conteúdo para adoção de animais utilizando a técnica do cosseno ponderado. **Texto Livre**, Universidade Federal de Minas Gerais (UFMG), v. 17, p. e42708, 2024. ISSN 1983-3652. Disponível em: <https://www.scielo.br/j/tl/a/8pJNCPVWDcscMCBRhShb3KC/>. Acesso em: 28 de abr. de 2024.

SANTOS, S. L.; DURAO, F. A. Um sistema de recomendação de rotas turísticas baseado em filtragem colaborativa. **Texto Livre**, Universidade Federal de Minas Gerais (UFMG), v. 16, p. e41397, 2023. ISSN 1983-3652. Disponível em: <https://doi.org/10.1590/1983-3652.2023.41397>. Acesso em: 27 de maio de 2024.

SCHRAMMEL, L. A. **Ferramenta de recomendação híbrida de objetos de aprendizagem com predição das necessidades personalizadas de cada estudante.** Dissertação (Mestrado) — Universidade Federal de Santa Maria (UFSM), 2023. Disponível em: <https://repositorio.ufsm.br/handle/1/30895>. Acesso em: 14 de out. de 2024.

SIMON, A. **Quais streamings você terá que assinar para ver futebol brasileiro em 2024.** 2024. Disponível em: <https://www.uol.com.br/esporte/colunas/allan-simon/2024/01/07/quais-streamings-voce-vai-precisar-assinar-para-ver-futebol-em-2024.htm>. Acesso em: 28 de maio de 2024.

UOL. **Pesquisa: Vôlei e F1 são esportes mais acompanhados no Brasil após futebol.** 2024. Disponível em: <https://www.uol.com.br/esporte/futebol/ultimas-noticias/2024/05/14/pesquisa-volei-e-f1-sao-esportes-mais-acompanhados-no-brasil-apos-futebol.htm>. Acesso em: 28 de maio de 2024.

WAZLAWICK, R. S. **Metodologia de pesquisa para ciência da computação**. 3. ed. Rio de Janeiro: GEN LTC, 2020. ISBN 978-85-951-5109-3.

XU, K. *et al.* Evaluation and optimization of intelligent recommendation system performance with cloud resource automation compatibility. **Applied and Computational Engineering**, v. 87, n. 1, p. 228–233, aug 2024. Disponível em: <https://www.preprints.org/manuscript/202407.2199/v1>. Acesso em: 14 de out. de 2024.

YOU, M. Research on the evaluation of algorithms of recommendation systems of we-media and possible future development. **Frontiers in Artificial Intelligence and Applications**, feb 2024. Disponível em: <https://ebooks.iospress.nl/doi/10.3233/FAIA231341>. Acesso em: 14 de out. de 2024.

YOUTUBE. **Vídeos recomendados**. 2023. Disponível em: https://www.youtube.com/intl/ALL_br/howyoutubeworks/product-features/recommendations/#overview. Acesso em: 28 de maio de 2024.

APÊNDICE A – PROTÓTIPO

As linhas apresentadas a seguir correspondem ao código em *Python* para o protótipo desenvolvido neste trabalho. Para melhorar a legibilidade e indicar quebras de linha no código que excedem a largura da página, foi utilizado um símbolo (seta vermelha) no início das linhas continuadas, sinalizando que se trata de uma continuação da linha anterior.

```

import numpy as np
from sklearn.metrics.pairwise import cosine_similarity

# Criação de Perfis de Usuários
users = {
    1: {'extroversao': 4, 'curiosidade': 5, 'visual': 1,
        ↪ 'verbal': 0, 'pratico': 0, 'analitico': 1},
    2: {'extroversao': 2, 'curiosidade': 3, 'visual': 0,
        ↪ 'verbal': 1, 'pratico': 1, 'analitico': 0},
    3: {'extroversao': 5, 'curiosidade': 4, 'visual': 1,
        ↪ 'verbal': 1, 'pratico': 0, 'analitico': 1},
    4: {'extroversao': 1, 'curiosidade': 2, 'visual': 0,
        ↪ 'verbal': 1, 'pratico': 1, 'analitico': 0},
    5: {'extroversao': 3, 'curiosidade': 5, 'visual': 1,
        ↪ 'verbal': 0, 'pratico': 1, 'analitico': 1},
    6: {'extroversao': 2, 'curiosidade': 1, 'visual': 0,
        ↪ 'verbal': 1, 'pratico': 0, 'analitico': 1},
    7: {'extroversao': 4, 'curiosidade': 3, 'visual': 1,
        ↪ 'verbal': 1, 'pratico': 1, 'analitico': 0},
    8: {'extroversao': 1, 'curiosidade': 4, 'visual': 0,
        ↪ 'verbal': 1, 'pratico': 0, 'analitico': 1},
    9: {'extroversao': 5, 'curiosidade': 5, 'visual': 1,
        ↪ 'verbal': 0, 'pratico': 1, 'analitico': 0},
    10: {'extroversao': 3, 'curiosidade': 2, 'visual': 0,
        ↪ 'verbal': 1, 'pratico': 1, 'analitico': 1}
}

# Criação de Perfis de Vídeos
videos = {
    1: {'highlight': 1, 'analise': 0, 'entrevista': 0,
        ↪ 'duracao': 5, 'visual': 1, 'verbal': 0},

```



```

2: {'highlight': 0, 'analise': 1, 'entrevista': 0,
    ↪ 'duracao': 15, 'visual': 0, 'verbal': 1},
3: {'highlight': 0, 'analise': 0, 'entrevista': 1,
    ↪ 'duracao': 9, 'visual': 1, 'verbal': 1},
4: {'highlight': 1, 'analise': 0, 'entrevista': 0,
    ↪ 'duracao': 10, 'visual': 1, 'verbal': 1},
5: {'highlight': 0, 'analise': 1, 'entrevista': 0,
    ↪ 'duracao': 20, 'visual': 1, 'verbal': 1},
6: {'highlight': 0, 'analise': 0, 'entrevista': 1,
    ↪ 'duracao': 12, 'visual': 0, 'verbal': 1},
7: {'highlight': 1, 'analise': 0, 'entrevista': 0,
    ↪ 'duracao': 7, 'visual': 1, 'verbal': 1},
8: {'highlight': 0, 'analise': 1, 'entrevista': 0,
    ↪ 'duracao': 8, 'visual': 0, 'verbal': 1},
9: {'highlight': 0, 'analise': 0, 'entrevista': 1,
    ↪ 'duracao': 16, 'visual': 1, 'verbal': 1},
10: {'highlight': 0, 'analise': 1, 'entrevista': 0,
     ↪ 'duracao': 18, 'visual': 1, 'verbal': 0}
}

```

Histórico de Interações dos Usuários

```

matriz_interacao = np.array([
#
#           Vídeos
#   1  2  3  4  5  6  7  8  9  10
[1, 0, 1, 1, 0, 0, 1, 0, 1, 0], # Arthur   (Usuário 1)
[0, 1, 0, 0, 1, 0, 0, 1, 0, 1], # Agatha  (Usuário 2)
[1, 0, 1, 1, 1, 1, 1, 0, 0, 0], # José    (Usuário 3)
[0, 1, 0, 0, 0, 1, 0, 1, 1, 1], # Vitoria (Usuário 4)
[1, 0, 0, 1, 1, 0, 1, 0, 0, 1], # Henrique (Usuário 5)
[0, 1, 1, 0, 0, 1, 0, 1, 1, 0], # Maria   (Usuário 6)
[1, 0, 1, 1, 0, 1, 1, 0, 1, 1], # Lucas   (Usuário 7)
[0, 1, 0, 0, 1, 0, 0, 1, 1, 0], # Laura   (Usuário 8)
[1, 0, 1, 1, 1, 0, 1, 0, 0, 1], # Matheus (Usuário 9)
[0, 1, 0, 0, 1, 1, 0, 1, 0, 0], # Sofia   (Usuário 10)
])

```

Função para recomendação por Filtragem Colaborativa

```

def recomendacao_fc(user_id, matriz_interacao,
    ↪ top_recomendacoes=2):

```

```

user_similares = cosine_similarity(matriz_interacao)

user_pontuacao_similaridade = user_similares[user_id - 1]

pontuacao_ponderada = np.dot(user_pontuacao_similaridade ,
    ↪ matriz_interacao)

user_interacao = matriz_interacao[user_id - 1]

pontuacao_ponderada = pontuacao_ponderada *
    ↪ (user_interacao == 0)

videos_recomendados =
    ↪ np.argsort(pontuacao_ponderada)[: -1][: top_recomendacoes]
    ↪ + 1

return videos_recomendados

# Função para recomendação por Filtragem Baseada em Conteúdo
def recomendacao_fbc(user_id, users, videos,
    ↪ top_recomendacoes=2):
    user_atributos =
        ↪ np.array(list(users[user_id].values())).reshape(1,
        ↪ -1)

    video_atributos = np.array([list(videos[vid].values()) for
        ↪ vid in videos])

    video_similarities = cosine_similarity(user_atributos,
        ↪ video_atributos).flatten()

    videos_recomendados =
        ↪ np.argsort(video_similarities)[: -1][: top_recomendacoes]
        ↪ + 1

return videos_recomendados

# Função para recomendação híbrida, que combina Filtragem
    ↪ Colaborativa e Filtragem Baseada em Conteúdo

```

```
def recomendacao_hibrida(user_id, matriz_interacao, users,
    ↪ videos, peso_fc=0.5, top_recomendacoes=2):
    fc_recomendacao = recomendacao_fc(user_id,
        ↪ matriz_interacao,
        ↪ top_recomendacoes=top_recomendacoes)

    fbc_recomendacao = recomendacao_fbc(user_id, users,
        ↪ videos, top_recomendacoes=top_recomendacoes)

    pontuacoes_finais = {}

    for vid in fc_recomendacao:
        pontuacoes_finais[vid] = peso_fc

    for vid in fbc_recomendacao:
        if vid in pontuacoes_finais:
            pontuacoes_finais[vid] += (1 - peso_fc)
        else:
            pontuacoes_finais[vid] = (1 - peso_fc)

    recomendacao_final = sorted(pontuacoes_finais,
        ↪ key=pontuacoes_finais.get,
        ↪ reverse=True)[:top_recomendacoes]

    return recomendacao_final

# Gera as recomendações para cada usuário
for user_id in users.keys():
    recomendacoes = recomendacao_hibrida(user_id,
        ↪ matriz_interacao, users, videos, top_recomendacoes=3)

    recomendacoes = list(map(int, recomendacoes))
    print(f"Recomendações para o usuário {user_id}: Vídeo(s)
        ↪ {', '.join(map(str, recomendacoes))}")
```