

PONTIFÍCIA UNIVERSIDADE CATÓLICA DE SÃO PAULO

DESIGN DE INTERAÇÃO

Allan de Aguiar Calisto
Gabriel Veras Nogueira
João Victor Alves Messias
Leonardo Matos Cabral

**A INFLUÊNCIA DO DESIGN INFORMATIVO E A VISUALIZAÇÃO
DE DADOS APLICADOS À EXPERIÊNCIA DO USUÁRIO
EM SISTEMAS DE RECOMENDAÇÃO DE
PLATAFORMAS DE *STREAMING***

SÃO PAULO

2023

Allan de Aguiar Calisto
Gabriel Veras Nogueira
João Victor Alves Messias
Leonardo Matos Cabral

**A INFLUÊNCIA DO DESIGN INFORMATIVO E A VISUALIZAÇÃO
DE DADOS APLICADOS À EXPERIÊNCIA DO USUÁRIO
EM SISTEMAS DE RECOMENDAÇÃO DE
PLATAFORMAS DE STREAMING**

Trabalho de Conclusão de Curso apresentado à banca examinadora da Pontifícia Universidade Católica de São Paulo, como requisito para a obtenção do título de bacharel do curso de Design de Interação.

Orientadores: Prof. Dr. Diogo Cortiz e Prof. Dr. Thiago Mittermayer.

SÃO PAULO
2023

AGRADECIMENTOS

Agradecemos aos nossos professores e orientadores pela sua dedicação e orientação constante ao longo deste processo. Seus conhecimentos, paciência e incentivo foram fundamentais para o nosso crescimento acadêmico e profissional.

Agradecemos igualmente aos nossos amigos e familiares. Vocês foram uma fonte constante de apoio emocional, encorajamento e motivação durante toda a jornada. Suas palavras de incentivo e compreensão foram essenciais para que pudéssemos enfrentar os desafios e superar as adversidades.

Agradecemos também à PUC-SP, por proporcionar um ambiente propício ao aprendizado e pela oportunidade de desenvolver este TCC.

Também somos gratos aos colegas de curso e demais pessoas que colaboraram direta ou indiretamente com este trabalho. Suas contribuições, discussões e trocas de ideias foram extremamente valiosas para a construção e aprimoramento deste estudo.

RESUMO

O trabalho faz uma abordagem acerca dos sistemas de recomendação, que ao longo dos anos, são responsáveis por sugerir conteúdos relevantes, personalizados e atrativos a cada usuário, com base em seu respectivo histórico de uso e preferências. Destarte, a implementação de um sistema de recomendação eficiente, está baseado em *machine learning*, uma área da inteligência artificial, a qual desempenha um papel crucial na experiência do usuário e no sucesso dessas plataformas envolvidas. Com a finalidade de recomendar, tais algoritmos mostram-se como uma ferramenta de extrema importância para os negócios de empresas, a exemplo de *e-commerce*s (Amazon) e serviços de streaming (Netflix e Disney+), contribuindo para uma boa retenção de público. Para tanto, cabe destacar o descaso alarmante na efetividade da comunicação de fatores atrelados à coleta e privacidade de dados, visto que, tais sistemas são assiduamente precisos quanto à análise de perfil, salientando as preferências e interesses ideais de cada consumidor. Diante disso, se questiona como tais métodos de visibilidade e informação influenciam na usabilidade e na experiência do usuário em serviços *online* de *streaming* aplicados aos sistemas de recomendação de interfaces digitais. Neste sentido, a desmotivação e a frustração são sensações comuns de usuários que se preocupam com a crítica vulnerabilidade dos dados pessoais que circulam livremente entre algoritmos atuais. Outro aspecto que a transparência do uso de dados atrelada aos sistemas de recomendação pode atuar, é na influência e interação entre o usuário e a plataforma, o que pode contribuir para uma boa experiência, se efetuada corretamente, usando vieses psicológicos cognitivos atrelados ao design. Há inclusive, resultados que demonstram, a exemplo da Spotify que, por meio da clareza dos dados relatados, melhora a relação entre usuário e plataforma, a partir da aceitação do que é apresentado pela filtragem de similaridade, permitindo a criação de perfis de usuários individuais assertivos, além de respeitar os seus direitos de privacidade.

Palavras-chave: Visualização de dados, sistemas de recomendação, usabilidade, *streaming*.

ABSTRACT

The work takes an approach to recommendation systems, which, over the years, have been responsible for suggesting relevant, personalized, and attractive content to each user based on their respective usage history and preferences. Therefore, the implementation of an efficient recommendation system is based on machine learning, an area of artificial intelligence, which plays a crucial role in the user experience and the success of these platforms involved. For the purpose of recommendation, such algorithms prove to be an essential tool for the business of companies such as e-commerce (Amazon) and streaming services (Netflix and Disney+), contributing to good audience retention. To this end, it is worth highlighting the alarming disregard for the effectiveness of communicating factors linked to data collection and privacy, given that such systems are assiduously accurate in terms of profile analysis, highlighting the ideal preferences and interests of each consumer. Given this, the question arises of how such visibility and information methods influence the usability and user experience in online streaming services applied to digital interface recommendation systems. In this sense, demotivation and frustration are common sensations among users concerned about the critical vulnerability of personal data that circulates freely between current algorithms. Another aspect that transparency in the use of data linked to recommendation systems can act on is the influence and interaction between the user and the platform, which can contribute to a good experience, if carried out correctly, using cognitive psychological biases linked to design. There are even results that demonstrate, like Spotify, that through the clarity of the reported data, the relationship between user and platform improves based on the acceptance of what is presented through similarity filtering. Allowing the creation of assertive individual user profiles, in addition to respecting their privacy rights.

Keywords: Data visualization, recommendation systems, usability, streaming.

LISTA DE FIGURAS

Figura 1: Aprendizado Supervisionado	15
Figura 2: Ilustração de problemas de classificação e regressão	16
Figura 3: Dinâmica de machine learning não-supervisionado	17
Figura 4: Ilustração da filtragem colaborativa	20
Figura 5: Ilustração da filtragem baseada em conteúdo	22
Figura 6: Ilustração da filtragem híbrida	24
Figura 7: Playlist de “Novidades da Semana”	31
Figura 8: Playlists criadas com recomendações de músicas personalizadas	32
Figura 9: Exemplo da interface da Netflix	34
Figura 10: Comentário sobre a série Black Mirror da Netflix	35
Figura 11: Persona 1 - André	38
Figura 12: Persona 2 - Lucas	39
Figura 13: Persona 3 - Nicole	40
Figura 14: Protótipo de baixa fidelidade - Tela inicial	43
Figura 15: Protótipo de baixa fidelidade - Recomendações personalizadas	44
Figura 16: Protótipo de média fidelidade - Tela inicial	45
Figura 17: Protótipo de média fidelidade - Recomendações personalizadas	46
Figura 18: Protótipo de média fidelidade - Player de conteúdos	47
Figura 19: Protótipo de baixa fidelidade - Ideação de nova funcionalidade de recomendação	47
Figura 20: Planejamento do fluxo de telas	52
Figura 21 - 23: Primeira versão do protótipo modelo	52
Figura 24: Identidade Visual adaptada	54
Figura 25: Evento “TUDUM” da Netflix	55
Figura 26: Landing page do Protótipo Modelo	55
Figura 27: Página Principal do Protótipo Modelo	56
Figura 28: Lista de “Top 10 filmes e séries”	57
Figura 29: Nova Funcionalidade na aba “Para você”	57
Figura 30 e 31: Seleção de conteúdo	58
Figura 32: Aba “Bastidores” na Seleção de Conteúdo	59
Figura 33: Tela de apresentação dos “Bastidores”	60
Figura 34: Tela inicial dos “Bastidores”	61

Figura 35 e 36: Funcionalidade Linha do Tempo	62
Figura 37 - 39: Funcionalidade Retrospectiva	63
Figura 40 e 41: Pesquisa - Gênero e idade	70
Figura 42 e 43: Pesquisa - Plataformas e Gêneros de maior consumo	71
Figura 44: Pesquisa - Recomendação externa à plataforma.	72
Figura 45: Pesquisa - Conhecimento individual sobre dados	73
Figura 46: Pesquisa - Transparência das políticas de privacidade	74
Figura 47: Pesquisa - Avaliação de conhecimento	74

Sumário

1.	INTRODUÇÃO	11.1.	11.2.
21.3.			31.4.
31.4.1.			31.4.2.
41.5.			42.
	FUNDAMENTAÇÃO TEÓRICA	62.1.	66
2.2.	88		
2.3.	99		
2.4.	12		12
2.4.1.	14		14
2.4.2.	16		16
2.5.	17		17
2.5.1.	19		19
2.5.2.	21		21
2.5.3.	24		24
2.5.	28		28
3.	ESTADO DA ARTE	303.1.	303.2.
334.	DESCOBERTA E SEGMENTAÇÃO DE PÚBLICO ALVO	366	
4.1.	36		36
4.2.	37		37
4.2.1.	37		37
4.2.2.	38		39
4.2.3.	39		40
5.	41		41
5.1.	41		41
5.2.	42		42
5.2.1.	48		48
5.2.1.	51		51
5.2.	53		53
6.	65		65
7.	67		67

8.	70	70
8.1.	70	70
8.2.	76	76

1. INTRODUÇÃO

1.1. MOTIVAÇÃO

Com o avanço da tecnologia e o crescimento exponencial do consumo de conteúdo digital, plataformas de *streaming online* têm se tornado cada vez mais populares. Nesse contexto, a implementação de um sistema de recomendação eficiente baseado em *machine learning*, uma área da inteligência artificial, desempenha papel crucial na experiência do usuário e sucesso dessas plataformas.

Os sistemas de recomendação atuais utilizam algoritmos de inteligência artificial para analisar o perfil do usuário, destacando suas preferências e interesses, com a finalidade de recomendar filmes, séries e músicas, de forma personalizada. Ao aplicar esta tecnologia em plataformas de *streaming online*, é possível direcionar e facilitar a descoberta de conteúdos relevantes, proporcionando uma experiência mais satisfatória para o usuário.

Os recursos de algoritmos, quando aplicados em plataformas de *streaming*, criam uma análise numa grande quantidade de dados ao identificar padrões complexos sobre o perfil do usuário. Além disso, permite oferecer sugestões mais relevantes ao usuário (alinhados à respectiva relevância pessoal de escolhas) que, por sua vez, garante maior atividade na plataforma. Esse processo reduz a necessidade por uma pesquisa manual e apresenta ao cliente conteúdos direcionados a seus interesses, otimizando a usabilidade e a experiência da plataforma (YASUOKA, 2023).

Segundo Sigiliano e Faustino (2016), os sistemas de recomendação utilizados em plataformas de *streaming* se baseiam além do uso de algoritmos fornecidos por inteligência artificial. Ao levar em consideração conceitos de marketing e ações espontâneas dos usuários, como compartilhamento de preferências e dados sociais resultantes das redes midiáticas. Segundo os autores, essas ações disponíveis no sistema ajudam a induzir um sentimento de confiança entre os usuários.

Contudo, vale ressaltar que nem sempre os sistemas de recomendação terão os resultados desejados. A desmotivação e a frustração são sensações comuns de

Pontifícia Universidade Católica de São Paulo

usuários que não se identificam com as recomendações presumidas pelo algoritmo. Algo semelhante que pode levar o usuário a duvidar não só da eficácia da plataforma, mas também da segurança de seus dados. Infelizmente, em muitos casos, sugestões intrusivas e/ou excessivas acabam distanciando clientes das plataformas (YASUOKA, 2023).

Um sistema de visibilidade informacional eficiente em plataformas do tipo pode oferecer diversos benefícios, como contribuir em sugestões personalizadas, auxiliando na otimização do tempo de busca do usuário, proporcionando uma experiência mais eficiente e aumentando a sua satisfação. Contribuindo assim para uma fidelização do usuário à plataforma.

Além disso, a implementação dos sistemas de recomendações indica resultados comerciais significativos à plataforma. Ao permitir transparência nas informações coletadas e no direcionamento assertivo de conteúdos específicos, é possível aumentar a fidelização dos usuários à plataforma e a visualização de determinados filmes, séries e músicas. O que contribui para o aumento das taxas de engajamento e das receitas geradas pela plataforma.

Por fim, é notório afirmar que a capacidade de análise e entrega das preferências e necessidades individuais de cada usuário, vem se tornando cada vez mais assertiva. Porém, há uma crescente preocupação sobre a vulnerabilidade de informações pessoais que tais empresas, de caráter midiático administram. Por isso, é imperativo as plataformas de serviço online de streaming, uma participação ativa na garantia da privacidade e segurança dos dados de seus consumidores, na atribuição de sistemas de recomendação de qualidade, visando um aumento de satisfação dos usuários e impulsionando os resultados comerciais.

1.2. PERGUNTA DE PESQUISA

Tendo isso em vista, a pergunta da pesquisa consiste em: Como o Design Informativo e a Visualização de Dados influenciam na Experiência do Usuário aplicados aos Sistemas de Recomendação de plataformas de serviços de streaming?

1.3. HIPÓTESES

A pauta deste trabalho se baseou na busca da compreensão do tema abordado, visando a validação e/ou refutamento das seguintes hipóteses:

- I. Percebe-se que os sistemas de recomendação personalizados melhoram a usabilidade de serviços de *streaming online*, pois ao indicar conteúdos com base nos interesses individuais do usuário, há uma redução no tempo gasto pela busca por novos conteúdos.
- II. Se entende que, a precisão das recomendações do sistema influencia diretamente na satisfação do usuário nas plataformas digitais, pois se as indicações não forem coerentes com os gostos do usuário, a experiência será confusa e frustrante.
- III. Acredita-se que, sistemas de recomendação podem apresentar problemas, tendo dificuldades para cumprir seu papel, a exemplo na falha de exibição de novos conteúdos cativantes ao usuário final, limitando assim a experiência.
- IV. Crê-se que, o uso de elementos visuais informacionais e a aplicação do design informativo influenciam positivamente no engajamento e satisfação dos usuários, dispondo da otimização de interações entre usuário e plataforma.
- V. Julga-se que há necessidade de uma diversidade mais abrangente nos modos de visualização de dados, submetidos aos sistemas de recomendação, ansiando uma melhor percepção de valor e exploração de novos conteúdos.

1.4. OBJETIVOS

1.4.1. Objetivo Geral

Este trabalho tem como objetivo geral compreender e analisar o uso de sistemas de recomendação e como a integral inteligibilidade do uso de dados dos usuários pode auxiliar na experiência e usabilidade, em serviços de *streaming online*. De modo que seja visível entender a relevância da aplicação na experiência humano-máquina e no processo de consolidação da empresa que o aplica. Nessa perspectiva, se verifica quanto é impactante sua aplicação na jornada do usuário e recomendações de conteúdo dentro da plataforma, assim como, para compreender o porquê de ser tão fundamental no mundo dos *streamings* atualmente.

1.4.2. Objetivos Específicos

Considerando o objetivo geral, os resultados deste trabalho fazem uso dos seguintes objetivos específicos:

- I. Compreender como o sistema de recomendação funciona. Analisar quais são as etapas de contato com o usuário final, desde sua identificação até a interação e seus gostos, a fim de entender assim como potencializar as atividades.
- II. Comparar plataformas similares, e entender como se dá a aplicação dos conceitos e das funcionalidades dos sistemas de recomendação em suas propostas. Além de identificar problemas reais.
- III. Assimilar quais critérios e funcionalidades atribuídas decorrentes do Design Informativo auxiliam no método de exibição que favoreça na clareza e conhecimento do uso dos dados dos consumidores.
- IV. Replicar uma interface de serviço de *streaming*, projetando seu funcionamento digital, caracterizando a aplicação efetiva de uma modelagem gráfica interativa e intuitiva que aborde a demanda emergente da privacidade de dados dos usuários.

1.5. MATERIAIS E MÉTODOS

Este trabalho foi dividido em duas principais fases, nas quais iremos serão utilizadas as seguintes metodologias:

Na primeira fase foram aprofundados os assuntos que tangem o sistema de recomendação, usabilidade e influência disso para e com o usuário. A fim de atingir tal objetivo, foram realizadas pesquisas bibliográficas sobre: Coleta e filtragem de dados, design e visualização informativa, além de análise de produtos que utilizam sistemas de recomendação, mantendo o foco nas principais plataformas de serviços de streaming.

Durante a segunda fração do trabalho, nos baseamos em metodologias de criação de produtos, apresentando resultados já conquistados, a exemplo da Netflix, que por sua vez desfruta do modelo e desempenho ideal dos sistemas de Pontifícia Universidade Católica de São Paulo

recomendação. Com base no conhecimento adquirido por meio das escolhas dos perfis de seus usuários, analisamos e apresentamos resultados relacionados à usabilidade e dinâmica da adaptação informacional gráfica, a partir de pesquisas, testes e *feedbacks*.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. DESIGN DE INTERAÇÃO

Atualmente, dado aos avanços tecnológicos exponenciais, há uma maior interação entre humanos e máquinas, o que se torna cada vez mais comum e integrado ao cotidiano comum. “As pessoas agora estão gastando mais tempo em dispositivos digitais (laptops, celulares, dispositivos). Suas atividades digitais geram grandes quantidades de dados.” (NG, 2018, p. 10). Tal relação tem transformado radicalmente a forma como se vive, trabalha e se conecta.

A relação entre humanos e máquinas tem se tornado uma constante de extrema importância de coexistência e colaboração. Estabelecemos uma dependência inerente sem nem percebermos. “Era como se os algoritmos mais antigos não soubessem o que fazer com todos os dados que temos agora.” (NG, 2018, p. 10). O que diverge do atual contexto, no qual os assistentes virtuais automatizam tarefas nos mais diversos dispositivos e máquinas (RIVEROS, 2017).

Consequente a isso, o Design de Interação surge como uma área que se concentra na criação de experiências significativas e eficazes para os usuários ao interagir com sistemas digitais. Mais do que simplesmente criar interfaces atraentes, o design de interação busca compreender e atender às necessidades, expectativas e comportamentos dos usuários, a fim de proporcionar experiências envolventes e satisfatórias (AGNER, 2023).

O design interativo reconhece que os sistemas digitais não existem em um vácuo, mas são utilizados por seres humanos com suas características cognitivas, emocionais e sociais. Portanto, o design de interação busca criar significados que se alinhem aos padrões naturais de comportamento humano, promovendo uma experiência intuitiva e fluida a quem a consome. Ao entender como as pessoas interagem com a tecnologia, designers podem antecipar suas necessidades, minimizar a curva de aprendizado e otimizar a usabilidade (SOUZA, 2004).

Nesse campo contemporâneo, surge da inteligência artificial, o aprendizado de máquina (*Machine Learning*). O termo refere-se a um conjunto de técnicas nas quais uma máquina aprende e melhora o desempenho. Sendo de vital importância ao design

de interação que envolve a compreensão dos sistemas subjacentes, especialmente em um cenário de sistemas de recomendação. Tais sistemas utilizam técnicas para analisar padrões de comportamento do usuário e oferecer sugestões personalizadas, nas mais diversas plataformas midiáticas. Corrobora Rouhiainen (2018), diz que a IA (inteligência artificial), cria uma capacidade das máquinas de usarem algoritmos para aprender com os dados e usarem o que foi aprendido para tomar decisões como um ser humano faria.

Discorre Ng (2018), que tem uma métrica de avaliação de número único, que acelera a inteligência artificial a tomar uma decisão decidida pelo usuário, entre um grande número de classificadores. Dita uma clara classificação de preferência entre todos eles e, portanto, uma direção clara para o progresso.

Portanto, toda essa “espinha dorsal” de relação entre usuário e plataforma, é formada por tais sistemas e é consolidada por um bom projeto de design interativo.

Retornando ao Design de Interação, este se baseia em padrões e princípios a fim de garantir uma experiência coesa e intuitiva. Um exemplo desses princípios são as 10 heurísticas sobre usabilidade de Nielsen. Visibilidade, Equilíbrio entre controle e liberdade, Consistência em padrões, Prevenção de erros e Eficiência de uso; por exemplo, são apenas algumas das diretrizes, que são baseadas na psicologia cognitiva e nos comportamentos do usuário, orientando os designers a criarem interfaces e sistemas que se alinhem às expectativas dos usuários (mesmo que de forma subconsciente). "Os melhores designers só produzem produtos de sucesso se os seus projetos resolverem os problemas certos. Uma interface maravilhosa para as funcionalidades erradas, falhará." (NIELSEN, 2007).

Uma parte fundamental da interação é a visualização de dados, que permite aos usuários compreenderem informações complexas de maneira acessível e envolvente. A arquitetura da informação cuidadosamente planejada organiza os dados e as recomendações de forma lógica, garantindo que os usuários possam acessar facilmente o que é relevante para eles. A visualização de dados e a arquitetura da informação se unem para tornar as interações mais claras e eficazes, aumentando a capacidade dos usuários de explorar recomendações de maneira significativa. (ALEXEI, 2021).

O design de interação é uma disciplina que transcende a estética visual, considerando o comportamento humano, as práticas de usabilidade, os padrões de interação e a integração de sistemas complexos, como os de recomendação. A eficácia dessa abordagem está em criar interfaces que se alinham às necessidades e expectativas dos usuários, tornando a interação com sistemas de recomendação de plataformas de streaming mais fluida e satisfatória. Ao combinar uma compreensão profunda do comportamento do usuário com a aplicação de padrões, princípios e técnicas de visualização de dados, é possível criar experiências que não apenas atendam às demandas de informação, mas também tornem a exploração e a tomada de decisão uma experiência gratificante e envolvente para os usuários.

2.2. USABILIDADE E EXPERIÊNCIA DO USUÁRIO (UX)

De acordo com Norman (2018), o Design é realmente um ato de comunicação, desta forma, comprehende um profundo entendimento de quem é a pessoa com quem o designer está se comunicando.

User Experience (UX) ou experiência do usuário é o conjunto dos sentimentos e atitudes vivenciados pelos usuários como resultado da interação com uma empresa ou um de seus produtos ou serviços. Já a Usabilidade é um atributo que mede as características do uso de uma interface. Essa interface pode ser por meio de botões, interruptores ou outros dispositivos físicos. Ela é comumente associada a recursos técnicos, como sites, aplicativos e softwares, propondo fazer desse site ou aplicativo mais fácil de ser executado, eficiente e/ou prazeroso.

Para Mitchell (1997), capacidade de adaptação do sistema às preferências e comportamentos do usuário é essencial para aprimorar a qualidade dessa interação. Essa adaptabilidade pode ser alcançada por meio do aprendizado de máquina e da coleta de dados, como histórico de interações, histórico de compras, avaliações e interações prévias.

Ensina Ganesan (1994) sobre o processo de interação entre o usuário e os sistemas de recomendação, que é permeado pelo constante processo de tomada de decisões. Exemplifica que em um relacionamento de longo prazo entre vendedor e comprador pode influenciar a forma como o usuário interage com o sistema.

Por isso, tanto a experiência do usuário quanto a usabilidade da interface devem ser pontos cruciais para um bom desempenho de plataformas virtuais. Tais ferramentas de design combinadas a um sistema de recomendação de qualidade, formam uma fórmula perfeita de sucesso de rentabilidade digital.

2.3. DESIGN INFORMATIVO E VISUALIZAÇÃO DE DADOS

A evolução das tecnologias digitais trouxe consigo a proliferação de vastas quantidades de dados. Que nada mais são que resultados de medições ou elementos perceptivos. Tais informações, muitas vezes complexas e abstratas, exigem meios eficazes de representação para serem compreendidos, interpretados e aplicados de forma significativa e funcional. Nesse contexto, existem duas áreas do conhecimento analítico que desempenham um papel fundamental na concepção eficaz dos dados. São elas a Visualização de Dados e a Arquitetura da Informação. (RIBEIRO, 2009).

A Visualização de Dados é uma área de estudo que busca um consenso na forma de representar informações complexas de forma visual, muitas vezes por meio de gráficos, diagramas e infográficos. Ela visa tornar os dados acessíveis e comprehensíveis, facilitando a identificação de padrões, tendências e insights. (RIBEIRO, 2009).

Por outro lado, a Arquitetura da Informação é responsável por organizar e estruturar informações de maneira lógica e eficiente, garantindo que os usuários possam encontrar o que procuram de forma intuitiva.

Visto que existe uma crescente nas diversas maneiras de captação e tipos de dados, é visível que existem um desafio na capacidade de processamento e compreensão dessas informações. Cada conjunto de dados apresenta necessidades específicas para cada método de exibição, e o propósito para o qual estes serão utilizados é fundamental na definição dessas necessidades. Por isso, devemos explorar a importância do planejamento na exibição de dados, e como isso se relaciona com a crescente sobrecarga de informações.

Mediante isto, é importante delimitar os principais objetivos na aplicação de qualquer projeto de visualização de dados. São eles:

- I. Clareza: A representação visual deve ser clara e fácil de entender. Isso envolve a escolha adequada de gráficos, cores e elementos visuais para evitar confusão e garantir que a informação seja comunicada de maneira eficaz.
- II. Precisão: Os dados representados devem ser precisos e refletir a realidade. Qualquer imprecisão ou distorção pode levar a interpretações errôneas.
- III. Eficiência: A visualização deve permitir que as informações sejam compreendidas de forma rápida e eficiente. Elementos visuais devem ser organizados de forma a facilitar a extração de insights.
- IV. Significado: Cada visualização deve ter um propósito claro e transmitir uma mensagem relevante, ajudando os espectadores a entenderem e interpretar os dados.

De acordo com Ben Fry (2008), existem sete estágios essenciais no desenvolvimento visual de um conjunto de dados, são eles:

I. Planejamento na Exibição de Dados:

O planejamento cuidadoso na exibição de dados é essencial para garantir que as informações sejam comunicadas eficazmente e compreendidas pelo público-alvo. Cada conjunto de dados tem suas particularidades, e o design da visualização deve ser adaptado para atender a essas necessidades específicas.

II. Sobrecarga de Informações:

Assim como a Economia da Atenção, a Sobrecarga de Informação consiste em um conceito que pauta a quantidade excessiva de conteúdo e informação e dados. Compreender como lidar com essa sobrecarga é fundamental para manter o foco e a eficácia na análise de dados.

III. Avanços Tecnológicos:

A tecnologia moderna revolucionou a forma como lidamos com os dados. Hoje, uma máquina acessível tem o poder de processar dados complexos que eram impensáveis no passado. Isso democratizou a análise de dados, tornando-a acessível a um público mais amplo.

IV. Coleta de Dados:

A primeira etapa no processo de entendimento de dados é a aquisição dos dados brutos. Garantir que os dados necessários estejam disponíveis é o primeiro passo para uma análise eficaz.

V. Formulação de Perguntas:

A formulação de perguntas específicas desempenha um papel crucial na análise de dados. Perguntas claras e específicas guiam a análise, tornando-a mais direcionada e produtiva.

VI. Processo de Entendimento de Dados:

O processo de entender dados envolve várias etapas, desde a análise até a representação e interação com os dados. Essas etapas transformam dados brutos em informações comprehensíveis e úteis.

VII. Integração de Disciplinas:

Para abordar eficazmente problemas de dados, é essencial integrar diversas disciplinas, como estatística, mineração de dados e design gráfico. Essa integração combina conhecimento técnico, design e comunicação.

VIII. Foco na Pergunta Original:

Manter o foco na pergunta original ao lidar com dados é fundamental para evitar dispersão de esforços e garantir que a análise e a visualização sejam relevantes.

Concluindo, o planejamento na exibição de dados desempenha um papel crítico na era da sobrecarga de informações. Compreender a importância de cada etapa no processo de entendimento de dados, desde a coleta até a visualização, é essencial para tomar decisões informadas e comunicar eficazmente informações valiosas em um mundo repleto de dados. A integração de disciplinas e o foco nas perguntas originais são os alicerces para enfrentar os desafios que os dados modernos apresentam.

Por fim, a aplicação deles em projetos de preservação de dados de usuários de plataformas de streaming, que usam dados para melhoria de sistemas de

recomendação. Não apenas aumentaria a confiança dos que usam tais plataformas, como também melhoraria a compreensão dos mesmos sobre como suas informações são usadas. Contribuindo assim à melhor adequação dessas grandes empresas em questões éticas cruciais na convivência digital, que tanto é debatida atualmente.

2.4. MACHINE LEARNING E RECOMENDAÇÕES

Atualmente, dado aos avanços tecnológicos exponenciais, há uma maior interação entre humanos e máquinas, o que se torna cada vez mais comum e integrado ao cotidiano comum. “As pessoas agora estão gastando mais tempo em dispositivos digitais (laptops, celulares, dispositivos). Suas atividades digitais geram grandes quantidades de dados.” (NG, 2018, p. 10). Tal relação tem transformado radicalmente a forma como se vive, trabalha e se conecta.

Aduz Ng (2018), que aprendizado de máquina (*Machine Learning*) é a base de inúmeras aplicações importantes, incluindo pesquisa, *antisspam* de e-mail, reconhecimento de voz, recomendações de produtos e muito mais. Neste contexto, diversas empresas que investiram na ideia foram beneficiadas. Dentre elas, as plataformas de serviço de *streaming online* tomaram uma parte intrínseca da vida social e cotidiana.

A relação entre humanos e máquinas tem se tornado uma constante de extrema importância de coexistência e colaboração. Estabelecemos uma dependência inerente sem nem percebermos. “Era como se os algoritmos mais antigos não soubessem o que fazer com todos os dados que temos agora.” (NG, 2018, p. 10). O que diverge do atual contexto, no qual os assistentes virtuais automatizam tarefas nos mais diversos dispositivos e máquinas.

Os algoritmos de recomendação fornecem conteúdo personalizado com base nas preferências dos usuários, nas mais diversas plataformas midiáticas. *Chatbots*, sistemas de reconhecimento de voz e veículos autônomos são apenas algumas das muitas outras aplicações de inteligência artificial. Discorre Ng (2018), que tem uma métrica de avaliação de número único, acelera a inteligência artificial a tomar uma decisão decidida pelo usuário, entre um grande número de classificadores. Dita uma

clara classificação de preferência entre todos eles e, portanto, uma direção clara para o progresso.

Nesse campo da inteligência artificial, o aprendizado de máquina se torna um dos principais métodos para construir sistemas inteligentes. Portanto, o termo *Machine Learning* refere-se a um conjunto de técnicas nas quais uma máquina aprende e melhora o desempenho.

Para que exerça uma função específica que não foi previamente e categoricamente programada. Corrobora Rouhiainen (2018), de que a IA (inteligência artificial), cria uma capacidade das máquinas de usarem algoritmos para aprender com os dados e usarem o que foi aprendido para tomar decisões como um ser humano faria.

Presentemente, a verdadeira relevância do aprendizado de máquina reside em sua capacidade de analisar grandes quantidades de dados e identificar padrões e relacionamentos ocultos. Ensina Ng (2018), acerca do exemplo de uma taxa de erro ideal (viés inevitável): 14%. Mesmo com o melhor sistema de fala possível, ainda existe possibilidade de 14% de erro, como a parte inevitável do viés de um algoritmo de aprendizado.

Com a ajuda de algoritmos inteligentes, os sistemas de aprendizado de máquina podem extrair informações valiosas e tomar decisões com base nesses *insights*, abrangendo desde o reconhecimento de padrões em imagens e textos até a previsão de comportamentos futuros.

Para Ng (2018), rótulos servem como medida de precisão dos humanos em relação a um conjunto de treinamento. Isso dá uma estimativa da taxa de erro ótima. Quando trabalhando em um problema os humanos têm dificuldade em resolver (por exemplo, prever qual filme recomendar ou qual anúncio mostrar a um usuário), pode ser difícil estimar a taxa de erro ideal.

Nesse contexto, o aprendizado de máquina se destaca como uma abordagem fundamental para o desenvolvimento de sistemas inteligentes que podem aprender e se adaptar aos dados. À medida que avançamos para um futuro cada vez mais

tecnológico, entender e aproveitar os benefícios do aprendizado de máquina é benéfico, transformador e orientado para o progresso da sociedade como um todo.

“A indução é a forma de inferência lógica que permite obter conclusões genéricas sobre um conjunto particular de exemplos” (REZENDE, 2003, p. 39). O que se pode entender que é a forma de se pensar que surge a partir de um conceito específico já existente, o que fornece uma base para uma análise geral.

Darwin, por exemplo, utilizou desse conhecimento para elaborar sua teoria da evolução e a seleção natural, apesar de sua dedicação incansável à coleta de dados empíricos e às extensas observações da natureza, reconheceu a importância da intuição como uma força motriz por trás de suas ideias revolucionárias.

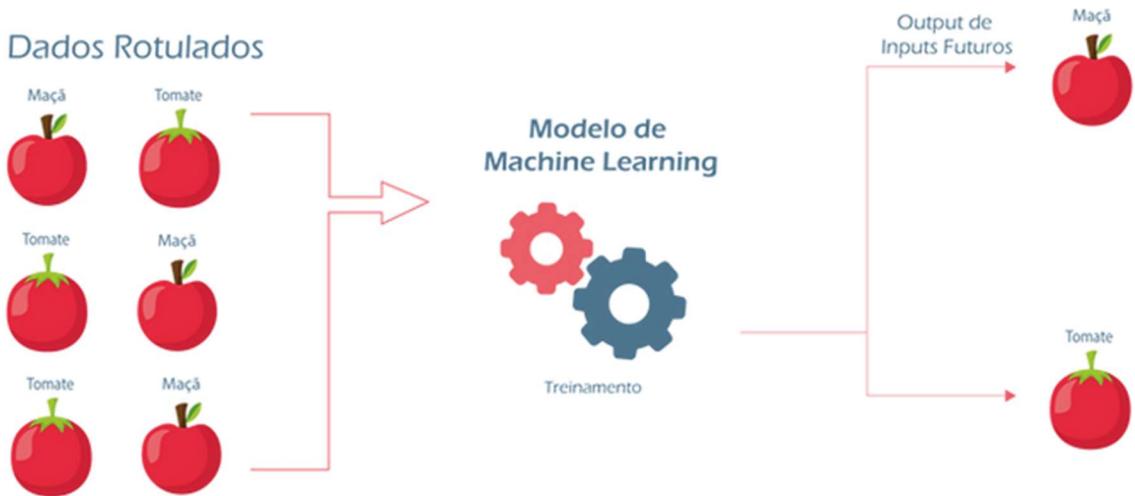
Do mesmo modo, máquinas também se baseiam no aprendizado intuitivo e da indução, utilizando de exemplos prévios ou analisando padrões para obter um resultado, que pode ser dividido em dois principais caminhos, os supervisionados (preditivos) e os não-supervisionados ou auto supervisionados (descritivos).

2.4.1. Aprendizado Supervisionado

“Para treinar um modelo de aprendizado supervisionado é necessário ter exemplos rotulados para que o algoritmo possa aprender a partir desses exemplos de treinamento.” (MARTINS, 2020, p. 53). Em resumo, tal método lida com as características reais de algum produto ou item, e após isso, utiliza-se dessa informação para se guiar no processo de aprendizagem.

Sendo essa uma das formas de aprendizado de redes neurais mais utilizadas geralmente. O método Supervisionado se baseia, portanto, no aprendizado de alguma função específica que mapeia uma entrada e uma saída a partir de exemplos pré-definidos para que, com a chegada de novos exemplos, qual seria a leitura correta daquela informação.

Figura 1. Aprendizado Supervisionado.



Fonte: Learning data. Disponível em: <www.learningdata.dev>. Acesso em: 3 out; 2023.

Expõe Rezende (2003), em uma linguagem técnica, que um algoritmo recebe um conjunto de exemplos com o objetivo de executar um processo ou função, e cada um desses exemplos se baseia em um vetor que possui características específicas e valores específicos, conhecidos como atributos, junto com o rótulo, que é a classe que o exemplo se encontra. Então, respectivo programa utiliza esses exemplos pré-determinados, para mapear caminhos dos rótulos que condizem com as classes certas e com características semelhantes.

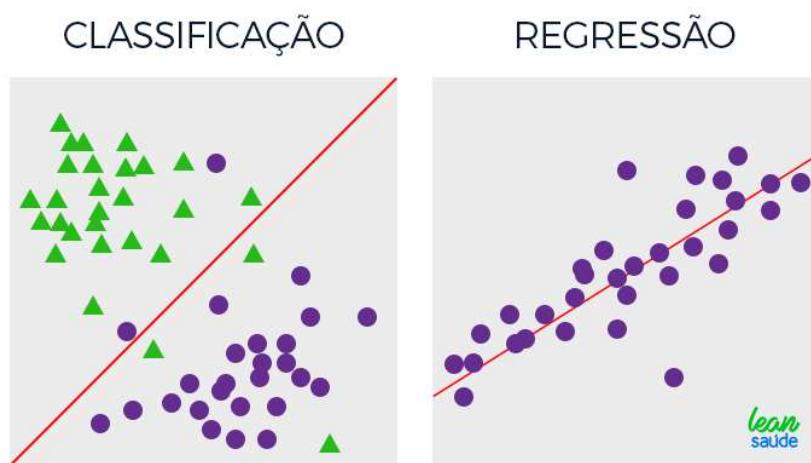
2.4.1.1. Problemas de Classificação e Regressão

Exibe Rezende (2003), que dentro do método de aprendizagem supervisionada, há dois dos principais modelos de problemas de processamento, que para rótulos de classe discretos, é conhecido como classificação; e para valores contínuos como regressão.

Para Fontes (2020), a abordagem de classificação trata de classificar se algum dado vale uma informação ou não, gerando um valor discreto, se este equivale a um grupo ou outro, classificando-o em determinado grupo seletivo. Um exemplo é o filtro de spam em e-mails, pois o algoritmo estudará com base em e-mails de spam já estabelecidos, se o e-mail que foi recebido é ou não considerado spam.

Da mesma forma, o problema de regressão vai gerar uma previsão ou uma análise a partir de dados com caminho mais contínuo, podendo te variar mais de uma opção de classificar. Segundo Fontes (2020), é a geração de uma análise de acordo com a variação das condições do dado. Um exemplo também pode ser observado na análise e previsão de trânsito em determinado horário do dia, de acordo com os horários já disponíveis em uma base de dados, que variam, ou seja, criam variáveis, isso exclui dados de somente sim ou não.

Figura 2. Ilustração de problemas de classificação e regressão.



Fonte: Lean Saúde. Acesso em: 3 out; 2023.

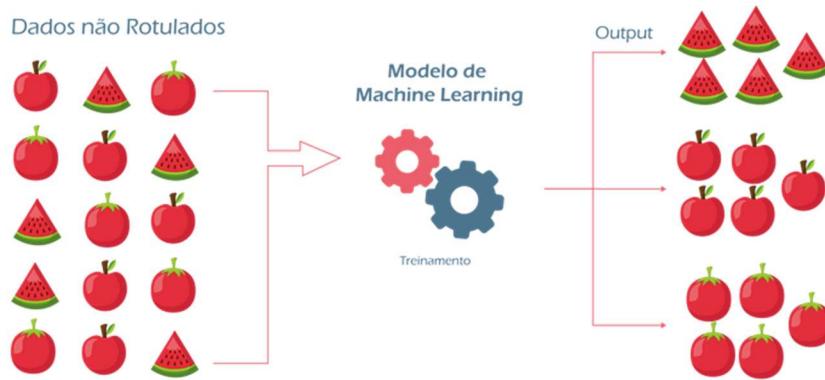
2.4.2. Aprendizado Não Supervisionado (Clusterização)

Instrui Araújo (2021), que aprendizado de máquinas não supervisionado é o aprendizado de máquinas em que os usuários não precisam supervisionar o modelo. Assim, não se faz uso do conhecimento de supervisor externo, sem um exemplo prévio. O algoritmo ao invés de predizer um valor, os algoritmos extraem padrões dos valores preditivos de um conjunto de dados.

Neste cenário, um respectivo programa procura por similaridades e padrões dentro das informações que serão processadas, e forma assim agrupamentos de acordo com esses padrões. De acordo com Cheeseman *et al.* (1990), esses grupos podem ser chamados de *clusters*. Em suma, se trata de uma rede neural que utiliza

de intuição para entender padrões e similaridade de características entre o que foi processado de acordo com o contexto que está sendo analisado.

Figura 3. Dinâmica de *machine learning* não-supervisionado.



Fonte: Disponível em: <www.learningdata.dev>. Acesso em: 3 out; 2023.

Discorre Verhalen (2019), que existem diversos sistemas e aplicativos que utilizam técnicas de aprendizado de máquina não supervisionado para oferecer funcionalidades e melhorias, mas um dos principais ramos de sistemas que utilizam, e, ao qual dar-se-á um enfoque maior. São os sistemas de recomendação em plataformas de serviços online, de streaming, como o Spotify e a Netflix, utiliza a IA de *machine learning* para sugerir opções de filmes e séries dentro de preferências selecionadas pelo usuário e, assim, mantê-lo interessado em assistir a sua programação, ao analisar padrões de comportamento do usuário e recomendar itens relevantes de acordo com características semelhantes.

2.5. SISTEMAS DE RECOMENDAÇÃO

Assevera Mitchell (1997) acerca da escolha para determinar exatamente que tipo de conhecimento será aprendido e como isso será usado pelo programa de desempenho. Considerando que um sistema de recomendação é uma ferramenta projetada para recomendar itens e conteúdos relevantes aos usuários com base em suas preferências, histórico de navegação, avaliações anteriores e outros comportamentos semelhantes do usuário.

Para serviços de *streaming online*, como plataformas de música, filmes e séries, os sistemas de recomendação desempenham um papel fundamental para

ajudar os usuários a descobrirem conteúdos novos e interessantes, facilitar a navegação e melhorar a satisfação geral do usuário. “Aqui consideramos uma família de algoritmos para aprender conjuntos de regras com base na estratégia de aprender uma regra” (MITCHELL, 1997, p. 275). A coleta de dados e informações é um aspecto importante da eficácia dos sistemas de recomendação.

Para Mitchell (1997) aprender com *feedback* de treinamento direto é normalmente mais fácil do que aprender com *feedback* indireto. Os serviços de *streaming* fornecem acesso a esses dados de várias maneiras. Por exemplo, o histórico de navegação, avaliações e preferências designadas de um usuário podem ser coletados por meio da interação direta com o sistema, como avaliações, favoritos e até listas de reprodução personalizadas. Além disso, informações implícitas, como cliques, tempo de tela e informações demográficas, podem ser coletadas para entender os perfis e preferências do usuário.

Existem dois tipos principais de *feedback* usados em sistemas de recomendação: explícito e implícito. “Um atributo-chave é se a experiência de treinamento fornece feedback sobre as escolhas feitas pelo sistema de desempenho”. (MITCHELL, 1997, p. 17). O retorno explícito vem por meio de classificações e preferências direcionadas ao usuário. Por exemplo, classificações de estrelas, gostos e desgostos para conteúdo específico. O retorno implícito vem do comportamento do usuário, como cliques, tempo de reprodução e interações do sistema. Ambos os tipos de *feedback* são importantes para entender as preferências do usuário e melhorar a precisão das recomendações.

Os sistemas de recomendação usam várias técnicas de filtragem para gerar recomendações personalizadas para os usuários. Expõe Mitchell (1997), que o campo de aprendizado, *machine learning*, está preocupado com a questão de como construir programas de computador que melhoram automaticamente com a experiência, por meio de sistemas de filtragem de informações que aprendem as preferências de leitura dos usuários.

Dentre as filtragens mais eficazes, temos a filtragem colaborativa que identifica usuários com interesses semelhantes e recomenda artigos com base nas preferências

de outros usuários semelhantes. Essa abordagem nos permite descobrir novos conteúdos com base em recomendações de pessoas com gostos semelhantes.

Outra filtragem que se destaca é baseada em conteúdo que analisa as propriedades do artigo e sugere artigos semelhantes a artigos nos quais os usuários já estão interessados, levando em consideração atributos como gênero, atores e artistas semelhantes. As recomendações híbridas combinam abordagens de filtragem colaborativas e baseadas em conteúdo, aproveitando ambas para fornecer recomendações mais precisas e diversificadas.

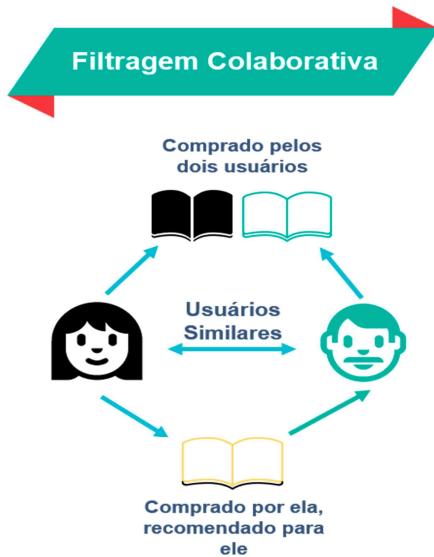
2.5.1. Filtragem Colaborativa

Mitchell (1997) exemplifica o conceito alvo "notícias eletrônicas que considero interessantes", ou "páginas na *World Wide Web* que discutem tópicos de aprendizado de máquina". Em ambos casos, se um computador pudesse aprender o conceito alvo com precisão, ele poderia filtrar automaticamente o grande volume de documentos para apresentar apenas os mais relevantes para o usuário.

Para Oliveira (2019), sistemas de recomendação baseados em filtragem colaborativa são usados para sugerir itens para um determinado usuário a partir da opinião de outros usuários parecidos. A filtragem colaborativa é uma técnica de recomendação que se baseia na coleta e análise de dados sobre as preferências de um grupo de usuários.

Ela busca identificar similaridades entre esses usuários e utilizar essa informação para recomendar itens que possam ser do interesse de cada um deles. Essa abordagem é baseada no pressuposto de que usuários com preferências semelhantes em determinados itens também terão preferências semelhantes em outros itens, permitindo a criação de recomendações personalizadas.

Figura 4. Ilustração da filtragem colaborativa.



Fonte: Disponível em: <www.linkedin.com>. Acesso em: 3 out; 2023.

A filtragem colaborativa está presente em várias áreas do cotidiano, desde plataformas de streaming de música e vídeo até lojas online e redes sociais. “E também existem diversas abordagens que podem ser usadas para criar sistemas de recomendação, cada uma com suas vantagens e desvantagens”. (SILVA, 2019, p. 1). Alguns exemplos de aplicação incluem:

Recomendações de filmes e séries: Serviços como Netflix e Amazon Prime Video utilizam a filtragem colaborativa para sugerir conteúdos com base nas preferências dos usuários e em padrões identificados entre eles.

Recomendações de produtos: Grandes varejistas *online*, como Amazon e Mercado Livre, fazem uso da filtragem colaborativa para oferecer recomendações personalizadas de produtos com base nas compras anteriores dos usuários e nas escolhas de outros consumidores com interesses semelhantes.

Redes sociais: Plataformas como Facebook e Instagram também se beneficiam da filtragem colaborativa para exibir conteúdos relevantes aos usuários, levando em consideração suas interações, preferências e conexões com outros usuários.

A filtragem colaborativa traz inúmeros benefícios para o mercado que a utiliza, tanto para as empresas quanto para os usuários. Silva (2019) explica que para recomendar itens a um novo usuário há classificação, e, classes criadas, para gerar

as recomendações. Este método consegue ter uma cobertura alta mesmo em matrizes esparsas, aquelas onde há uma quantidade grande de elementos vazios. Alguns desses benefícios incluem:

- I. Melhora da experiência do usuário: Ao receber recomendações personalizadas e relevantes, os usuários têm uma experiência mais satisfatória e engajadora, encontrando facilmente itens de seu interesse, o que pode levar a um aumento na fidelização e satisfação do cliente.
- II. Aumento das vendas e receitas: Ao direcionar recomendações precisas, as empresas podem aumentar as chances de conversão, impulsionando as vendas e, consequentemente, suas receitas. A filtragem colaborativa permite identificar oportunidades de cross-selling e up-selling, oferecendo produtos complementares ou de maior valor aos usuários.
- III. Descoberta de novos itens e ampliação do catálogo: Através da filtragem colaborativa, é possível identificar itens menos conhecidos que possam interessar aos usuários, contribuindo para a descoberta de novos produtos e ampliando o catálogo oferecido pelas empresas.
- IV. Aprimoramento do marketing e segmentação de mercado: Com a filtragem colaborativa, as empresas podem entender melhor o perfil e as preferências de seus usuários, permitindo segmentar suas estratégias de marketing de forma mais efetiva. Isso leva a campanhas direcionadas, redução de desperdícios e otimização dos investimentos em publicidade.

2.5.2. Filtragem Baseada em Conteúdo

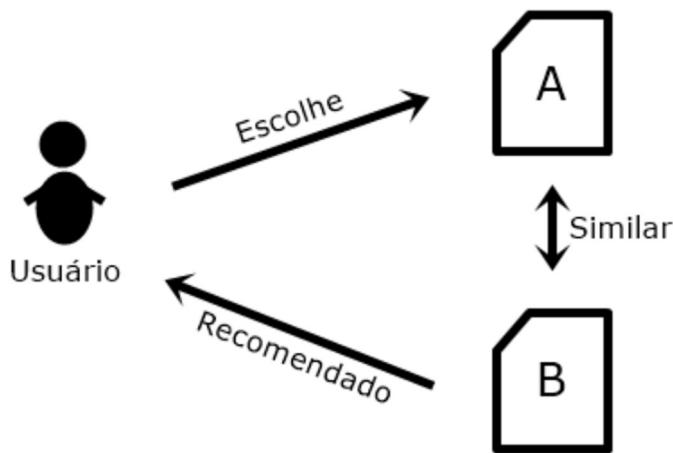
“A recomendação baseada em conteúdo tem origem na recuperação de informação, portanto ambas utilizam técnicas semelhantes” (SILVA, 2019, p. 4). Uma técnica eficaz amplamente utilizada em sistemas de recomendação é a filtragem com base no conteúdo, que visa fornecer recomendações personalizadas aos usuários baseadas nas características dos itens.

A filtragem com base no conteúdo difere da filtragem colaborativa, que se baseia nas preferências e comportamentos dos usuários. A filtragem com base no

conteúdo busca semelhanças entre itens por meio de descrição, categorias, palavras-chave e atributos. Para Silva (2019) diferente da filtragem colaborativa, que recomenda itens que usuários semelhantes ao usuário alvo gostaram, a por conteúdo recomenda itens parecidos com os itens que o usuário gostou. Essa abordagem centrada no conteúdo traz benefícios notáveis para o mercado atual e tem aplicações significativas no cotidiano, especialmente em plataformas de streaming.

Silva (2019) descreve a análise de características e metadados dos itens, como texto, imagem, gênero, diretor, elenco, entre outros, sendo utilizada para identificar padrões e similaridades. Com essas informações, o sistema de recomendação pode sugerir itens que possuam características semelhantes aos itens que o usuário demonstrou interesse anteriormente.

Figura 5. Ilustração da filtragem baseada em conteúdo.



Fonte: Disponível em: <www.researchgate.net>. Acesso em: 3 out; 2023.

Aduz Silva (2019) que há vantagens nesta técnica, pois não depende da avaliação de outros usuários, e sim em apenas os itens avaliados pelo usuário alvo importam. Ademais, é capaz de recomendar itens que ainda não foram avaliados por nenhum usuário e é possível saber quais as *features* fizeram um determinado item ser recomendado. A filtragem de conteúdo é amplamente aplicada no cotidiano de quem utiliza plataformas online. Aqui estão alguns exemplos:

- I. Recomendação de filmes e séries: plataformas como Netflix, Amazon Prime Video e Disney + sugerem filmes e séries usando filtros de conteúdo. O sistema recomenda conteúdo que seja semelhante ao que o usuário já assistiu ou

demonstrou interesse com base nas características dos títulos, como gênero, diretor, elenco e sinopse.

- II. Recomendação de músicas: Os serviços de streaming de música, como o Spotify e o Apple Music, oferecem aos usuários músicas e playlists sugeridas usando filtros baseados no conteúdo. As sugestões são baseadas em elementos musicais, como gênero, ritmo, instrumentação e artistas, que sejam comparáveis aos que o usuário prefere.
- III. Recomendação de produtos: Lojas online, como Amazon e eBay, também utilizam a filtragem com base no conteúdo para recomendar produtos aos usuários. Ao analisar as características dos produtos, como descrição, marca, categoria e atributos, o sistema pode oferecer produtos semelhantes aos que o usuário pesquisou ou comprou anteriormente.

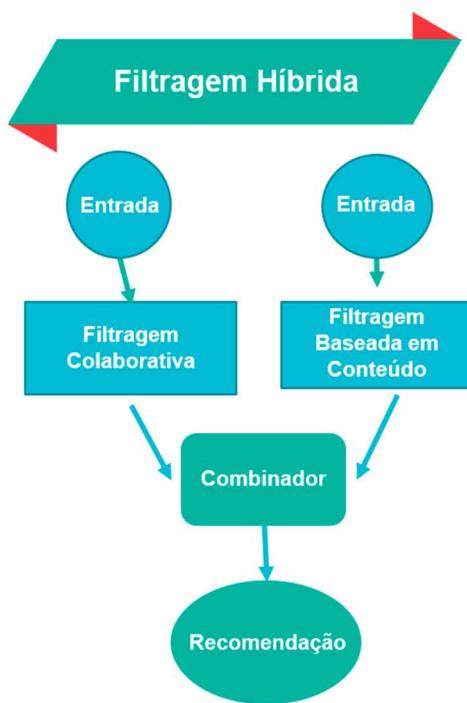
Para Silva (2019), apesar de que não é possível fazer uma análise muito complexa do conteúdo, a filtragem com base no conteúdo traz benefícios significativos para o mercado atual, especialmente nas plataformas de *streaming*. Ao contrário da filtragem colaborativa baseada nas avaliações e preferências de outros usuários, a filtragem baseada em conteúdo também pode recomendar itens novos ou subestimados. Isso reduz a dependência de informações limitadas e permite recomendações mais precisas. Apesar disso, alguns benefícios incluem:

- I. Personalização aprimorada: a filtragem baseada em conteúdo fornece recomendações altamente personalizadas que consideram as preferências individuais do usuário, levando em consideração as características essenciais dos artigos. Isso torna a experiência de streaming mais imersiva e satisfatória.
- II. Descoberta de novos conteúdos: novos filmes, séries, músicas e artistas com filtragem baseada em conteúdo. Ao sugerir itens semelhantes aos itens já avaliados pelo usuário, o sistema de recomendação amplia o catálogo e estimula a exploração de conteúdos diversos.

2.5.3. Filtragem Híbrida

Ensina Silva (2019) que sistemas híbridos combinam mais de um tipo de técnica com o objetivo de ampliar as vantagens de cada uma e diminuir as desvantagens associadas a cada método. A filtragem híbrida é uma abordagem amplamente utilizada em sistemas de recomendação, que combina os princípios de filtragem colaborativa e filtragem baseada em conteúdo.

Figura 6. Ilustração da filtragem híbrida.



Fonte: Disponível em: <www.linkedin.com>. Acesso em: 3 out; 2023.

Segundo Ricci (2011), o objetivo dos sistemas de recomendação híbridos, é combinar diferentes técnicas de recomendação, desse modo, se aproveitam as vantagens de cada abordagem para superar suas respectivas limitações individuais. A combinação de filtragem colaborativa e filtragem baseada em conteúdo tem sido uma abordagem comumente adotada, neste sentido, proporcionam recomendações mais precisas e diversificadas.

Referida filtragem usa uma combinação de técnicas que consideram as preferências do usuário e as características do item recomendado. Em plataformas de *streaming*, por exemplo, isso é feito avaliando um perfil de usuário que pode ser criado

com base no histórico de interação deste com a plataforma e em características de itens como gênero, atores, diretor, enredo etc. A implementação da filtragem híbrida a um projeto de sistema de recomendação tem muitos benefícios. Primeiro, oferece uma estratégia mais ampla que aproveita o melhor entre as duas outras filtragens. Isso oferece uma gama maior de indicações mais relevantes e atraentes ao usuário.

Além disso, pode resolver problemas como *Cold Starts* que ocorrem quando novos usuários ou itens são adicionados à plataforma e informações do mesmo são insuficientes ou não estão disponíveis para fazer recomendações. “Este problema ocorre com novos usuários ou novos itens, pois o número de notas iniciais é pequeno ou inexistente, tornando-se difícil aplicar os métodos tradicionais” (SILVA, 2019, p. 8). Ao combinar técnicas de filtragem colaborativa e baseada em conteúdo, o sistema pode fazer recomendações com base em perfis de usuários e características de itens semelhantes, mesmo com informações bem mais limitadas.

Para Silva (2019), técnicas de hibridização podem ser classificadas de sete maneiras: *Weighted*, *Switching*, *Mixed*, *Feature combination*, *Cascade*, *Feature augmentation*: no *Feature augmentation* e *Meta-level*. No entanto, a aplicação da filtragem híbrida também apresenta desafios.

Um dos principais desafios é encontrar o equilíbrio adequado entre os dois tipos de filtragem. A ponderação correta das contribuições de cada técnica é fundamental para garantir recomendações relevantes. Além disso, a integração de diferentes algoritmos e métodos de filtragem pode ser complexa, exigindo um trabalho cuidadoso de desenvolvimento e ajuste para garantir um desempenho eficiente e preciso.

Outro desafio está relacionado à escala e ao processamento de grandes quantidades de dados. As plataformas de *streaming* têm enormes conjuntos de dados que precisam ser processados rapidamente para fornecer recomendações em tempo real. Lidar com a complexidade computacional e o armazenamento de dados é uma tarefa desafiadora, que requer infraestrutura computacional adequada e técnicas avançadas de coleta, análise e processamento de dados.

Apesar disso, a filtragem híbrida continua sendo uma estratégia mais promissora para sistemas de recomendação. Com a evolução contínua das

tecnologias de processamento de dados e *Machine Learning*, espera-se que a filtragem híbrida se torne ainda mais sofisticada e eficaz, impulsionando a qualidade das recomendações e a satisfação do usuário.

2.5.4. Obstáculos das Filtragens

Apesar dos diversos benefícios que diferentes tipos de filtragem fornecem em um sistema de recomendação. No entanto, as filtragens também apresentam obstáculos que podem prejudicar o desempenho das plataformas que as utilizam. Para Silva (2019) são três: o problema de *Cold Start*, esparsidade e escalabilidade.

2.5.4.1. Obstáculos na Filtragem Colaborativa

A filtragem colaborativa, apesar de ser uma técnica eficaz para sistemas de recomendação, enfrenta desafios e problemas que podem limitar sua aplicação e precisão.

Cold Start: “O caso de novos usuários, o sistema precisa aprender suas preferências antes de recomendar algum item. E no caso de novos itens, o sistema não irá recomendá-los somente se houver quantidade considerável de avaliações” (SILVA, 2019, p. 8). Portanto, no *Cold Start* há falta de informações suficientes sobre usuários ou itens para realizar recomendações precisas. Principalmente na filtragem colaborativa, o *Cold Start* é um grande desafio porque o sistema depende do histórico de interações entre usuários e itens para encontrar padrões e gerar recomendações relevantes. Quando um novo usuário se registra ou um novo item é adicionado à plataforma, quase não há dados significativos disponíveis para análise.

De acordo com Vijaysinh (2021), tal problema é especialmente importante quando o recomendador faz parte do serviço prestado aos usuários. Isto posto, se um usuário apenas recebe recomendações de baixa qualidade pode optar por deixar o sistema antes de fornecer interação suficiente para permitir que o recomendador entenda seus interesses. Ao lidar com novos usuários, a técnica principal é solicitar que eles ofereçam certas preferências para criar um perfil de usuário inicial.

Escreve Faria (2020) sobre a Esparsidade de dados, como sendo um desafio comum na filtragem colaborativa, especialmente em plataformas com grandes

conjuntos de dados. O problema ocorre quando o número de usuários e itens é muito grande e, consequentemente, a interação entre eles é limitada. Isso produz uma matriz de prioridade esparsa com muitas células vazias.

A densidade de dados esparsos dificulta a detecção de padrões de similaridade entre usuários ou itens, afetando a precisão das recomendações. Além disso, a esparsidade também pode levar a uma alta dependência de usuários populares ou itens populares, resultando em uma falta de diversidade nas recomendações.

Para Betina *et al.* (2018), a Escalabilidade é um desafio técnico associado ao processamento eficiente de grandes quantidades de dados em tempo real. À medida que as plataformas de recomendação continuam a crescer e o número de usuários e itens aumenta, os algoritmos e os sistemas de filtragem colaborativa precisam ser capazes de lidar com a carga de trabalho e fornecer recomendações oportunas. Realizar cálculos complexos de similaridade entre usuários ou entre itens em escala é computacionalmente intensivo e requer uma infraestrutura adequada para atender a demanda.

2.5.4.2. Obstáculos na Filtragem Baseada em Conteúdo

Pondera Silva (2019) que filtragem baseada em conteúdo parte da ideia que itens similares são avaliados de maneira similar por um mesmo usuário. Portanto, as notas de um usuário em filmes de ficção científica poderiam ser usadas para prever a nota de outros filmes do mesmo gênero, mesmo que o usuário ainda não tenha assistido. A filtragem baseada em conteúdo também apresenta desafios distintos que podem afetar sua eficácia. A seguir, destacamos dois desses desafios:

Betina *et al.* (2018) delineia sobre uma análise de conteúdo limitada: A filtragem baseada em conteúdo analisa as características do item para fazer recomendações. Um desafio, no entanto, é a limitada análise de conteúdo. Nem sempre é fácil extrair propriedades significativas de todos os tipos de elementos, como música, vídeos e imagens.

Além disso, a análise de conteúdo pode ser limitada a informações disponíveis ou estruturadas, como metadados e tags, que podem afetar a precisão das recomendações. Se a análise de conteúdo não for suficientemente detalhada ou

precisa, pode afetar a capacidade do sistema de recomendação de entender as preferências do usuário e fornecer recomendações relevantes.

Além disso, a superespecialização de conteúdo refere-se a situações em que um sistema de recomendação coloca muita ênfase na recomendação de itens semelhantes aos itens que o usuário já consumiu, limitando assim os tipos de recomendações. Isso pode ocorrer porque a filtragem baseada em conteúdo é baseada nas características dos próprios itens e nas preferências do usuário com base nos itens anteriores.

No entanto, isso pode resultar na falta de exploração de novos itens ou em uma gama limitada de interesses do usuário. A falha do sistema em reconciliar recomendações de itens semelhantes e novos ou diferentes pode levar a uma experiência de recomendação estagnada e imprevisível (BETINA, 2018).

2.6. SERVIÇOS DE STREAMING

Para Oliveira (2019), serviços de *streaming* fazem parte da vida diária de milhares de pessoas ao redor do mundo. Tiveram seu surgimento e ganharam espaço nos últimos dez anos. Essa grande evolução se deu muito por conta do desenvolvimento da Internet, que rapidamente evoluiu, possibilitando pessoas de se comunicar, fazer compras, consumir conteúdos de onde e quando quisessem.

Antes, o que era uma prática de ir a locadora alugar um filme ou ver pela tv aberta, por exemplo, e de ouvir músicas pelo rádio ou até ir a uma loja física comprar um CD passou a ser possível, devido à internet, consumi-los através dos chamados serviços de *streaming*. Com isso, o usuário consegue acessar os conteúdos de qualquer dispositivo com acesso a internet, sendo um computador, celular, tablet, ou smart TV, e quando quiser, não dependendo de uma programação fixa, como acontece na TV ou no rádio, por exemplo.

Como explana Ferrareli *et al.* (2020) ao automatizar determinados processos, incide que o *streaming* torna o consumo, uma experiência mais passiva. As redes P2P (*peer-to-peer*), pelo contrário, exigiam uma participação ativa do utilizador para descobrir novas músicas, pois não havia qualquer tipo de categorização e era necessário o descarregamento dos arquivos antes de poder ouvi-los.

Apresenta Oliveira (2019), que os mais conhecidos e assinados streamings de filmes são: Netflix, tendo cerca de 151 milhões de assinantes em 190 países. Globoplay no Brasil, com mais de 20 milhões de assinantes apenas no Brasil. Já para União Brasileira de Compositores (2023), *streamings* de música com maior acesso é Spotify, com 489 milhões de assinantes.

Além dos principais nomes, outros no mercado também se fazem presente, como a Amazon Prime Video, Apple TV+, Disney+, HBO MAX para streaming de filmes, Deezer e Amazon Music para streaming de músicas e Xbox Game Pass, Playstation Plus, e GeForce Now para streaming de jogos diretamente da nuvem.

3. ESTADO DA ARTE

Nos textos subsequentes, serão apresentados exemplos reais de plataformas de *streaming online* que utilizam de sistemas de recomendação para fazer a indicação de conteúdos personalizados aos usuários, e revelar processo de coleta de dados.

3.1. SPOTIFY

O Spotify é uma plataforma de streaming voltada ao consumo da primeira arte (expressões artísticas que envolvem o som) que transformou completamente a forma como as pessoas descobrem e ouvem suas músicas. Fundada em 2006, na Suécia, por Daniel Ek e Martin Lorentzon, o aplicativo conquistou um crescimento gigantesco desde então. No começo, o Spotify enfrentou desafios para obter licenças de gravadoras e alcançar um público global, mas aos poucos expandiu sua presença para mais de 180 países, tornando-se uma das principais referências no mundo do streaming de música (MAMEDE, 2023).

Explicam Demarco e Santos (2021), que um dos segredos do sucesso do Spotify está em seu sistema de recomendação altamente eficiente. Ao longo dos anos, a empresa investiu consideravelmente no desenvolvimento de algoritmos avançados de IA e *Machine Learning*, buscando entender os gostos e as preferências musicais de seus usuários.

O sistema de recomendação do Spotify é alimentado por uma combinação de dados que incluem o histórico de audição de cada usuário, informações demográficas e até mesmo *feedback* explícito dos próprios usuários como curtidas ou ocultar músicas de *playlists*.

A experiência de navegação e a usabilidade do aplicativo do Spotify são amplamente elogiadas por milhões de usuários em todo o mundo. Sua interface intuitiva permite que as pessoas encontrem facilmente músicas, álbuns e artistas de seu interesse.

“O surgimento das plataformas de streaming revolucionou a forma das pessoas ao consumir conteúdos de forma digital, mudando e monitorando comportamentos.” (FERRARELI et al., 2020, p. 3). Proeminente destacar que essa plataforma é utilizada

em todo o mundo, e permite que os usuários ouçam músicas sem a necessidade de download, sendo uma forma de consumo legalizada.

Um dos pontos fortes da plataforma é a capacidade de personalização, permitindo que os usuários criem suas próprias *playlists* com base em suas preferências musicais. Além disso, segundo Demarco e Santos (2021), o recurso “Novidades da Semana” apresenta uma lista de músicas recomendadas com base nos gostos de seu usuário, proporcionando uma experiência musical personalizada e cativante.

Figura 7. Playlist de “Novidades da Semana”.



Fonte: Aplicativo Spotify. Acesso em: 18 jun; 2023.

Neste caso, o algoritmo analisa o histórico de audição do usuário, levando em consideração as músicas que foram curtidas, as *playlists* criadas, os artistas e gêneros que são seguidos. Com base nesses dados, o sistema gera recomendações personalizadas, apresentando novas músicas, artistas e *playlists* que possam interessar ao usuário.

Um de seus novos recursos é a ordem aleatória inteligente, que tem como ideia tornar randômico a ordem das músicas de uma playlist e introduzir músicas novas e que combinem com a playlist no meio desta filtragem.

Figura 8. Playlists criadas com recomendações de músicas personalizadas.



Fonte: Aplicativo Spotify. Acesso em: 18 jun; 2023.

Existem diversos tipos de filtragem relevantes dentro do sistema de recomendação do Spotify, incluindo a similaridade musical, a popularidade, a descoberta de novos lançamentos e as tendências do momento.

A filtragem de similaridade permite que o sistema sugira músicas e artistas semelhantes aos que o usuário já gosta, enquanto a filtragem por popularidade leva em consideração as tendências atuais.

O recurso de descoberta de novos lançamentos agrada muito os usuários, pois mantém todos atualizados sobre os últimos lançamentos de seus artistas favoritos. A combinação desses filtros contribui para criar uma experiência personalizada, mantendo os usuários engajados e satisfeitos com o serviço.

O sistema de recomendação do Spotify desempenha um papel fundamental na rentabilidade da empresa, ao fornecer recomendações precisas e relevantes, o Spotify aumenta a satisfação do usuário e, consequentemente, o seu número de assinantes.

Além disso, segundo Dantas e Menezes (2019), o sistema de recomendação influencia diretamente o tempo de uso do aplicativo, pois incentiva os usuários a explorarem novas músicas e artistas. Quanto mais tempo os usuários passam no aplicativo, maiores são as chances de se ouvirem anúncios ou optarem por uma assinatura paga, contribuindo para a renda da empresa.

Destarte, o Spotify possui uma história muito impactante de evolução e conquistando uma base global de usuários fiéis. A navegação e usabilidade são amplamente elogiadas, pois, oferecem aos que utilizam a plataforma, uma experiência personalizada e agradável. O sistema de recomendação do Spotify desempenha um

papel crucial em sua rentabilidade, ao fornecer recomendações precisas e relevantes, mantendo os usuários engajados e satisfeitos com a plataforma.

3.2. NETFLIX

A Netflix é uma das maiores empresas de entretenimento audiovisual do mercado, oferecendo séries e filmes em seu serviço de assinatura. Fundada em 1997 por Reed Hastings e Marc Randolph, nos Estados Unidos, a empresa era uma locadora de DVDs por correio, entregando filmes e séries em sua casa.

Em 2007, aconteceu uma grande transformação na empresa, onde ela introduz seus serviços de streaming online, permitindo que as pessoas assistissem o que quisessem, por onde quisessem com apenas um clique, oferecendo um catálogo inteiro e descartando o aluguel de DVDs e a demora de entrega, revolucionando o mercado.

Uma das principais características que diferenciam a plataforma de seus concorrentes desde sua origem, é seu sistema de recomendação que oferece aos seus usuários uma experiência personalizada e consegue recomendar novos conteúdos de forma que agrade os gostos e preferências dos usuários.

Ao se utilizar a plataforma, a Netflix cria perfis de usuários individuais com base nos dados coletados, ficando mais preciso conforme o tempo de uso e consequentemente conhecendo melhor seus usuários. Esses perfis também podem ser utilizados em análises de padrões, correlações e comparação entre os consumidores finais.

Discorre Verhalen *et al.* (2019) que referida plataforma se utiliza dois métodos para alimentar sua IA: (I) Algoritmo de Recomendação, onde um filme escolhido por um usuário é buscado em outros perfis de usuários, permitindo identificar preferências semelhantes, o que gera novas recomendações [1]; e (II) Banco de Dados de Pôsteres, que consiste em gerar pôsteres diferentes para um mesmo filme, levando em consideração a região do usuário, atores mais frequentes nas escolhas de seus filmes e os filmes assistidos recentemente.

Além de todo o algoritmo de recomendação, a percepção da interface da Netflix e a experiência de usabilidade do serviço seguem um padrão de opiniões positivas, sendo uma interface simples e intuitiva, acompanhada de um design limpo e organizado deixando os botões e menus sempre em fácil acesso garantindo uma experiência agradável para todos os usuários.

Figura 9. Exemplo da interface da Netflix.



Fonte: Aplicativo Netflix. Acesso em: 22 jun; 2023.

A Netflix também investe muito na responsividade da sua interface, sendo projetada para ser fluida e se ajustar automaticamente em qualquer dispositivo utilizado, os elementos da interface, como menus, botões e imagens, são dimensionados e reorganizados de forma inteligente para se adequar ao tamanho da tela, mantendo sua visualização agradável e mantendo uma familiaridade independente de onde o usuário utilize.

De um modo geral, a Netflix consegue se destacar de seus concorrentes com seu sistema de recomendação inteligente, conseguindo analisar, entender e classificar seus usuários de forma a personalizar sua experiência além de manter um padrão de fluidez e familiaridade com sua interface intuitiva e altamente responsiva.

Um ponto também curioso sobre a Netflix é que algumas séries e filmes são criados com base em dados captados por algoritmos sobre o que as pessoas estão mais se interessando. Questão essa satirizada pela série Black Mirror da própria Netflix, no primeiro episódio da 6º temporada.

Figura 10. Comentário sobre a série Black Mirror da Netflix.



Fonte: Série Black Mirror (Temporada 6 - Ep. 1) Acesso em: 22 jun; 2023.

A Netflix mantém controle nos algoritmos para gerar conteúdos relevantes, baseados nas preferências de seus usuários e, sobretudo, em ambientes externos, afirma Marcelo Trevisani, Head of Marketing Studio da CI&T.

4. DESCOBERTA E SEGMENTAÇÃO DE PERSONAS

O objetivo deste projeto consiste em implementar um novo padrão de responsabilidade informativa em plataformas de *streaming*. Para alcançar esse objetivo, foi feita uma pesquisa quantitativa por meio de questionários online, com o intuito de obter uma compreensão abrangente das diversas opiniões do público geral em relação à gestão de dados pessoais nesse contexto específico. Além disso, buscou-se verificar se tal preocupação é real aos usuários da plataforma, e validar as hipóteses inicialmente propostas no início do estudo.

4.1. PESQUISA QUANTITATIVA

A pesquisa quantitativa realizada envolveu mais de 60 participantes que forneceram insights significativos sobre o relacionamento destes com o uso de suas informações pessoais em serviços de plataformas de streaming. O estudo buscou compreender as percepções dos usuários em relação à coleta de dados e a transparência das políticas de privacidade oferecidas por tais empresas.

Vale salientar que a faixa etária predominante dos entrevistados foi de 62,5% de jovens, entre 15 a 24 anos. Sendo de sua maioria mulheres (50%).

A pesquisa revelou que a Netflix é a plataforma de *streaming* mais utilizada, mencionada por cerca de 37% dos entrevistados.

Uma descoberta relevante foi a observação de que os entrevistados consomem conteúdos além do que é recomendado pelas plataformas de streaming. Isso sugere que a recomendação não é o único, nem o principal fator que influencia suas escolhas.

Em relação ao conhecimento sobre a coleta de dados, a pesquisa apontou uma notória desinformação entre os entrevistados. A maioria não tem conhecimento claro sobre quais dados são usados para as recomendações de conteúdo.

A transparência das políticas de privacidade foi outro ponto de preocupação. Muitos entrevistados sentem que essas não são suficientes para entendimento do uso dos dados na plataforma. A falta de controle sobre mudanças nos consentimentos previamente dados também foi destacada.

Sobre os tipos de dados coletados, os participantes mencionaram uma variedade de informações, mas principalmente dados cadastrais e histórico de pesquisa. Os quais não são de extrema relevância à base dos sistemas de recomendação.

A pesquisa também investigou o interesse dos entrevistados à facilitação do acesso aos dados, o que gerou opiniões divergentes. Alguns desejam acesso máximo às informações coletadas, enquanto outros preferem apenas evitar vazamento de informações. Outrora uma parcela significativa não tem uma opinião formada ou não possui conhecimento suficiente para definir suas preferências.

4.2. PERSONAS

Com os resultados da pesquisa quantitativa e dos estudos e *insights* obtidos, deu-se início ao processo de desenvolvimento de personas e público-alvo para utilização das interfaces adaptadas à temática abordada.

As principais plataformas de *streaming* direcionam seus esforços a atender uma ampla variedade de espectadores, desde crianças até idosos, oferecendo um serviço adaptado aos desejos de cada faixa etária. Porém, quando abordamos o interesse na privacidade, percebe-se um interesse maior entre pessoas de 18 e 49 anos.

Partindo desse conhecimento e almejando o desenvolvimento assertivo do produto final, foram desenvolvidas três personas que representam os principais tipos de usuários, que visa-se obter na aplicação ideal do protótipo.

4.2.1. André

André, um desenvolvedor de software de 35 anos casado, residente no Rio de Janeiro. Ele é um apaixonado por tecnologia desde a juventude, resultando no seu profundo interesse na compreensão da Ciência da Computação.

Atualmente, André é um consumidor assíduo das principais plataformas de streaming, como Netflix, Amazon Prime Video e HBO Max. No entanto, ele não hesita em recorrer à pirataria quando necessário. Ele tem um forte interesse por filmes e

séries de suspense e investigação policial, com ocasionais incursões em gêneros mais leves quando está com a família.

Seu diferencial é sua consciência em relação à coleta de dados por parte das plataformas e sua busca por equilibrar privacidade e conveniência. Cotidianamente, suas preocupações se concentram na coleta de dados relacionados à localização, histórico de pesquisa e visualizações.

Para André, a transparência e o equilíbrio entre privacidade e personalização são cruciais ao desfrutar de conteúdo de *streaming* de qualidade.

Figura 11. Persona 1 - André.

Sobre

André é um apaixonado por tecnologia desde jovem. Sua trajetória o levou a estudar Ciência da Computação e hoje ele trabalha como desenvolvedor de softwares.

André é um usuário assíduo das principais plataformas de streaming: Netflix, Amazon Prime Video e HBO Max. Porém ele não hesita em recorrer à pirataria quando necessário.

Seu interesse como usuário é voltado para filmes e séries de suspense e investigação policial, e em raras exceções ele se aventura em gêneros relacionados a comédia, quando está com a família.

André acredita que compreender bem os dados que as plataformas coletam dele, e possui conhecimento conciso sobre o mercado de uso dos

Principal Desafio

André busca equilibrar sua paixão por tecnologia e filmes de suspense, mas reconhece que precisa se manter consciente da coleta de dados por parte das plataformas de streaming.

Necessidades

Equilíbrio entre privacidade e conveniência: André procura um equilíbrio entre a coleta de dados e a experiência aprimorada oferecida pelas plataformas.

Atualização tecnológica: Ele busca se manter atualizado com as inovações tecnológicas no campo da Ciência da Computação.

Entretenimento personalizado: André quer continuar a desfrutar de filmes de suspense e investigação policial sob medida para seus gostos.

Interesses e atividades

- Conhecimento aprofundado sobre Ciência da computação, programação e desenvolvimento de software.
- Recorrentemente assiste a filmes e séries de suspense e investigação policial
- Explora tecnologias e soluções inovadoras
- Aproveita promoções e sempre está atento sobre lançamentos de seu interesse.

Preocupações com privacidade

Ele acredita que a localização é um dado crucial avaliado pelas plataformas.

André entende que suas escolhas, principalmente voltadas ao conteúdo assistido, contribuem para a análise de seu perfil por parte das plataformas.

Ele reconhece que há extrema facilidade no acesso de dados restritivos dos usuários, e comprehende que tal exposição pode ser usada de maneira antiética para a fixação dos consumidores.

Relato Pessoal

"Tenho conhecimento que as plataformas se aproveitam do fácil acesso a informação, observando e analisando o comportamento humano para extrair o máximo de seus aplicativos. O processo de coleta de dados é complexo para os leigos e na maioria das vezes se passa despercebido, o que acaba permitindo que as empresas coletem mais informações e lucrem mais. Eu, individualmente, estou disposto a pagar pelo preço de parecer vulnerável para ter acesso aos conteúdos de meu interesse."

Fonte: Projeto pessoal.

4.2.2. Lucas

Lucas, um jovem solteiro de 25 anos de Fortaleza, que tem um profundo interesse em assuntos globais como política, filosofia, culturas diversas e principalmente Relações Internacionais, área que decidiu estudar na universidade.

Fora isso, Lucas é um ávido consumidor de música, recorrendo diariamente ao Spotify e ao YouTube para desfrutar de sua paixão. Lucas também nutre interesses em outros tipos de arte ao pesquisar sobre novas culturas. Quando se trata de entretenimento cinematográfico, ele é um grande fã de filmes de super-heróis e segue de perto as tendências da mídia.

Embora tenha preocupações sobre privacidade *online*, ele admite que possui pouco conhecimento sobre como seus dados são usados, inclusive em serviços de streaming.

Figura 12. Persona 2 - Lucas.



Lucas Alves

Sobre
Desde jovem, Lucas demonstrou interesse em assuntos globais e culturas diversas, o que acarretou no interesse em Relações Internacionais na universidade. Além disso, é apaixonado por música e usa diariamente plataformas como Spotify e YouTube. Possui interesses também por política e filosofia, porém atualmente sua maior ocupação consiste em descobrir e aprender um pouco mais sobre as outras artes. Quando o assunto é conteúdo cinematográfico, Lucas é fã de filmes de super-heróis e costuma acompanhar as tendências impostas pela mídia. Embora tenha preocupações sobre privacidade online, ele confessa que se dispõe pouco a entender como são usados dados e nunca se preocupou com o uso deles em serviços de streaming em específico.

Principal Desafio
Lucas convive com a sensação de perda de controle sobre seus dados pessoais e sabe que dados são coletados em diversos meios midiáticos, inclusive plataformas de serviços de streaming. Porém, ele não possui conhecimento prévio de como administrar melhor suas informações em seu cotidiano.

Necessidades
Transparéncia de dados: Lucas gostaria de uma visão clara das informações que os serviços estão coletando e como estão usando esses dados. **Opcões de privacidade:** Ele deseja ter mais controle sobre quais informações compartilha e com quem. **Fontes confiáveis:** Lucas procura fontes confiáveis de informação para entender melhor as implicações da coleta de dados e as medidas de proteção de privacidade que pode adotar.

Interesses e atividades
● Se entretém com a descoberta e entendimento de novas culturas.
● Consome diversos gêneros musicais recorrentemente, e está em busca compreender novas expressões artísticas.
● Possui interesse por filmes de super-heróis, mas acompanha predominantemente conteúdos tendenciosos da mídia.

Preocupações com privacidade
Ele acredita que suas escolhas em plataformas de streaming revelam muito sobre seus interesses pessoais. Lucas não sabe o que ele pode fazer para ter uma vida mais protegida digitalmente. Ele se interessa por compreender tal área e espera que plataformas midiáticas e de conteúdo adaptem a forma que esse tema é abordado.

Sobre uso de dados
"Não me sinto tão consciente das informações que as plataformas estão pegando de mim. Acho complicado entender completamente todo o processo e gostaria que essas empresas fossem mais transparentes no modo que usam nossas informações. Às vezes me pergunto se essa complexidade é intencional para que eles possam nos manipular e quem sabe coletar mais dados."

Idade 25
Cargo Relações Institucionais
Status Solteiro
Reside Fortaleza, CE

"Às vezes, fico desconfortável com o fato de que as plataformas sabem mais sobre mim do que eu mesmo. Parece que estão bisbilhotando todos os aspectos da minha vida."

Fonte: Projeto pessoal.

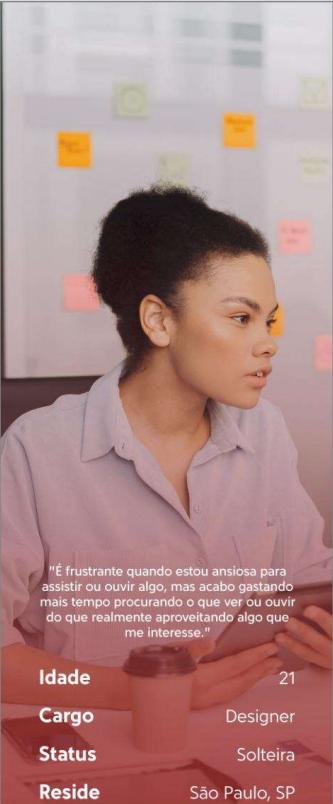
4.2.3. Nicole

Nicole, é uma jovem solteira de 21 anos que mora em São Paulo. Durante a infância demonstrava interesse por desenho e histórias, se considerando uma criança criativa.

No presente, devido à ansiedade, ela busca manter sua mente ocupada, buscando progresso na sua carreira profissional. Em seus momentos de lazer, ela gosta de assistir filmes e séries relacionados a comédia.

Nicole demonstra não ter conhecimento prévio sobre como e quais dados seus são utilizados. Somado a isso, também não aparenta se preocupar em compartilhar alguns dados pessoais em troca de uma recomendação mais assertiva por parte das plataformas de streaming.

Figura 13. Persona 3 - Nicole.



Nicole Almeida

Sobre

Desde a infância, Nicole sempre demonstrou grande criatividade. Adorando desenhar e criar histórias fantásticas. Hoje, devido à sua ansiedade, ela apenas busca manter a mente ocupada e focar na sua vida profissional.

Em seus momentos de descanso, costuma passar o tempo assistindo a séries de comédia, sempre com seus fones de ouvido por perto.

Nicole não se preocupa em compartilhar seus dados pessoais em troca de acesso a plataformas de streaming.

Principal Desafio

Nicole enfrenta o desafio de encontrar atividades que possam ocupar sua mente e evitar que ela se perca em seus próprios pensamentos. Ela busca por músicas, séries ou filmes que a entretenha. Fora isso, Nicole não demonstra preocupação nem conhecimento sobre como suas informações são utilizadas.

Necessidades

Gestão da ansiedade: Nicole precisa de métodos para lidar com sua ansiedade e encontrar atividades que a ajudem a relaxar.

Não se importa com privacidade de dados: Nicole não possui conhecimento e nem demonstra interesse algum sobre proteção e privacidade de dados

Interesses e atividades

- Busca focar em sua carreira profissional
- Tem o consumo de filmes e séries como seu principal lazer

Preocupações com privacidade

Ela não detém conhecimento mínimo de como seus dados são utilizados.

Teme o vazamento de dados pessoais básicos como endereço, email e CPF, mas não sabe como isso afetaria sua privacidade.

Sobre uso de dados

“É frustrante quando estou ansiosa para assistir ou ouvir algo, mas acabo gastando mais tempo procurando o que ver ou ouvir do que realmente aproveitando algo que me interesse. Sendo bem sincera, costumo nem ler os termos de condição dos aplicativos que uso, e costumo não me importar com o uso dos meus dados a princípio, contanto que a plataforma me entregue o que quero assistir.”

Idade	21
Cargo	Designer
Status	Solteira
Reside	São Paulo, SP

Fonte: Projeto pessoal.

5. DESENVOLVIMENTO E RESULTADOS

5.1. IDEAÇÃO

Foi idealizado na proposta realizar dois protótipos. Cujos quais tenham como base uma mesma plataforma de serviço de *streaming* já consolidada no mercado, a Netflix. Porém, tais protótipos terão aplicações distintas.

O **Protótipo 1 - Pesquisa**, foi usado na realização de um teste de usabilidade e interação do usuário com a plataforma. A fim de descobrir a viabilidade da apresentação de conteúdos que promovam uma melhor visibilidade e acesso a dados pessoais coletados, que estejam relacionados ao sistema de recomendação da plataforma.

Tal protótipo é de média fidelidade e foi usado como simulação de uma plataforma de *streaming* focado em conteúdos audiovisuais (filmes e séries). Já a pesquisa foi dividida em três etapas: Pesquisa pré-interação (que medirá o perfil ideal do entrevistado), Interação (uso do protótipo adaptado a cada indivíduo) e Pesquisa pós-interação (onde serão relatadas opiniões e considerações sobre a proposta, visando confirmar a eficácia da proposta escolhida).

O **Protótipo 2 - Modelo**, tem como objetivo demonstrar como seria a aplicação ideal da proposta apresentada e comprovada pela pesquisa realizada anteriormente. Reafirmando a implementação de uma melhoria na transparência do uso de dados coletados pelas plataformas, por meio de projetos de visualização de dados como:

I. Histórico e *Timeline* de Lançamentos:

Uma linha do tempo interativa que destaca de forma concisa os filmes já assistidos e os lançamentos recentes ao longo do tempo. Os usuários podem navegar pela linha para ver o que foi lançado em diferentes anos e meses, além de verificar sua influência na data decorrente.

II. Mapa de Visualização de Popularidade por Localização:

Disponibilidade de um mapa interativo que mostra a popularidade de filmes e séries em diferentes regiões geográficas. Possibilitando aos usuários clicarem em um

país ou cidade para ver quais filmes e séries populares nessa área, com base na coleta de visualizações e classificações de usuários.

III. Gráfico de Gêneros Interativo:

Apresentar um gráfico interativo que mostra a distribuição de gêneros de filmes e séries disponíveis no aplicativo que sejam de interesse do usuário. É uma adaptação do sistema básico de recomendação já implementado no aplicativo, porém com uma atribuição mais clara de como essa recomendação foi escolhida, além de propor uma forma de interação diferente.

IV. Retrospectiva:

Painéis que apresentam destaques individuais do ano. Mostrando quais foram os gêneros mais assistidos, títulos com mais “tempo de tela” e uma comparação entre os outros usuários do mesmo perfil em estilo gamificado (estimulando uma competição e interação entre os participantes).

5.2. DESENVOLVIMENTO

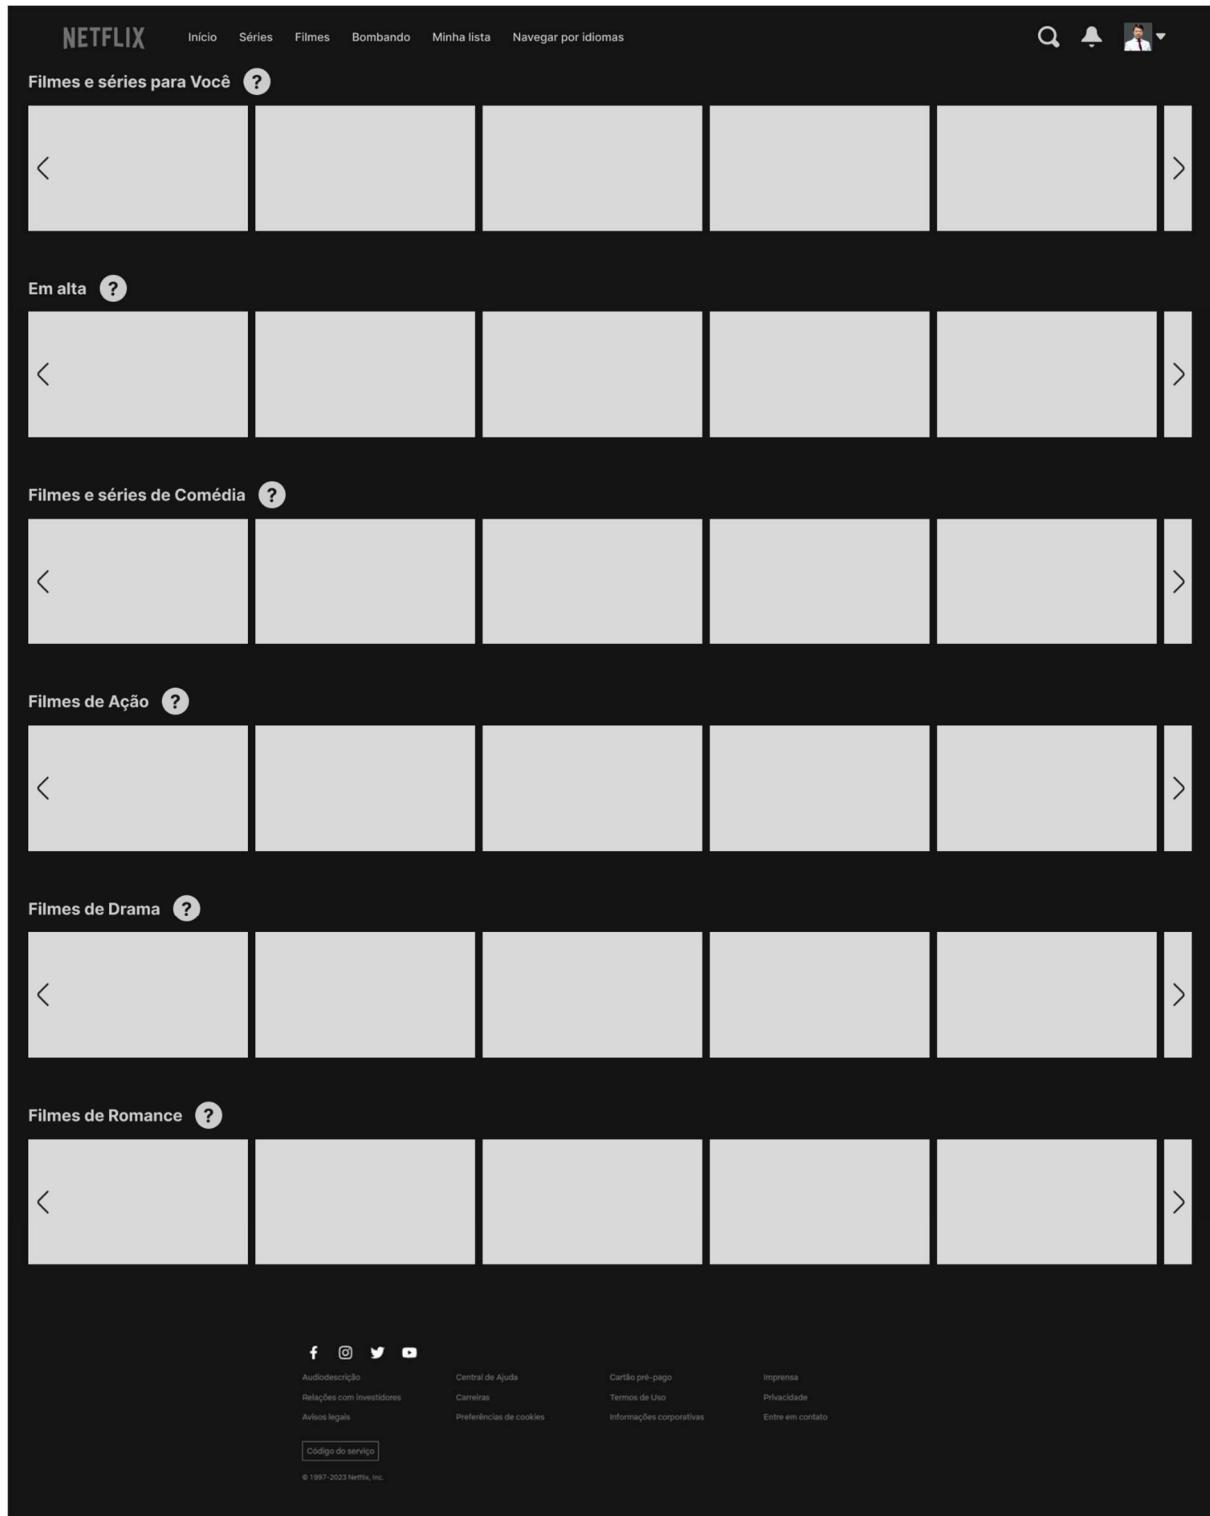
Com intuito de reunir dados e informações concretas a respeito da eficácia do protótipo apresentado na ideação, realizamos uma pesquisa qualitativa por meio de interações com o produto e entrevistas *online*, visando extrair funcionalidades informativas instrutivas aos usuários de plataformas de *streaming*, a respeito da coleta e uso de seus próprios dados.

Com os resultados dessa pesquisa foram validadas algumas hipóteses, relacionadas a usabilidade e aplicabilidade da ferramenta na plataforma, mesmo considerando a imperícia técnica dos participantes a respeito do funcionamento dos sistemas de recomendação.

A princípio determinamos os primeiros *wireframes* somente usando elementos básicos e estruturantes. Sem imagens ou cores, definindo assim o protótipo de média fidelidade, a fim de realizar testes com usuários para obter *feedbacks*.

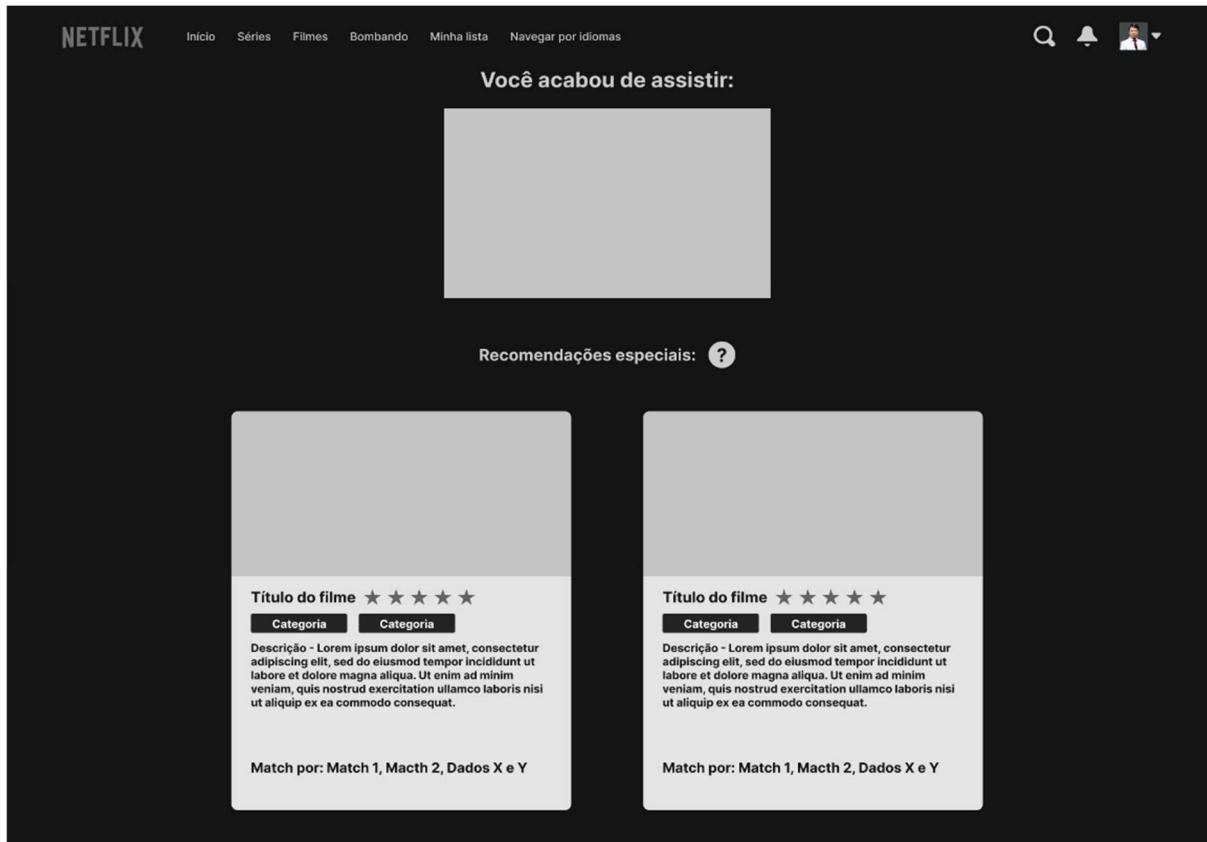
A seguir serão mostradas imagens do protótipo de baixa fidelidade (usado como *wireframe*) e média fidelidade (usado na interação):

Figura 14. Protótipo de baixa fidelidade - Tela inicial



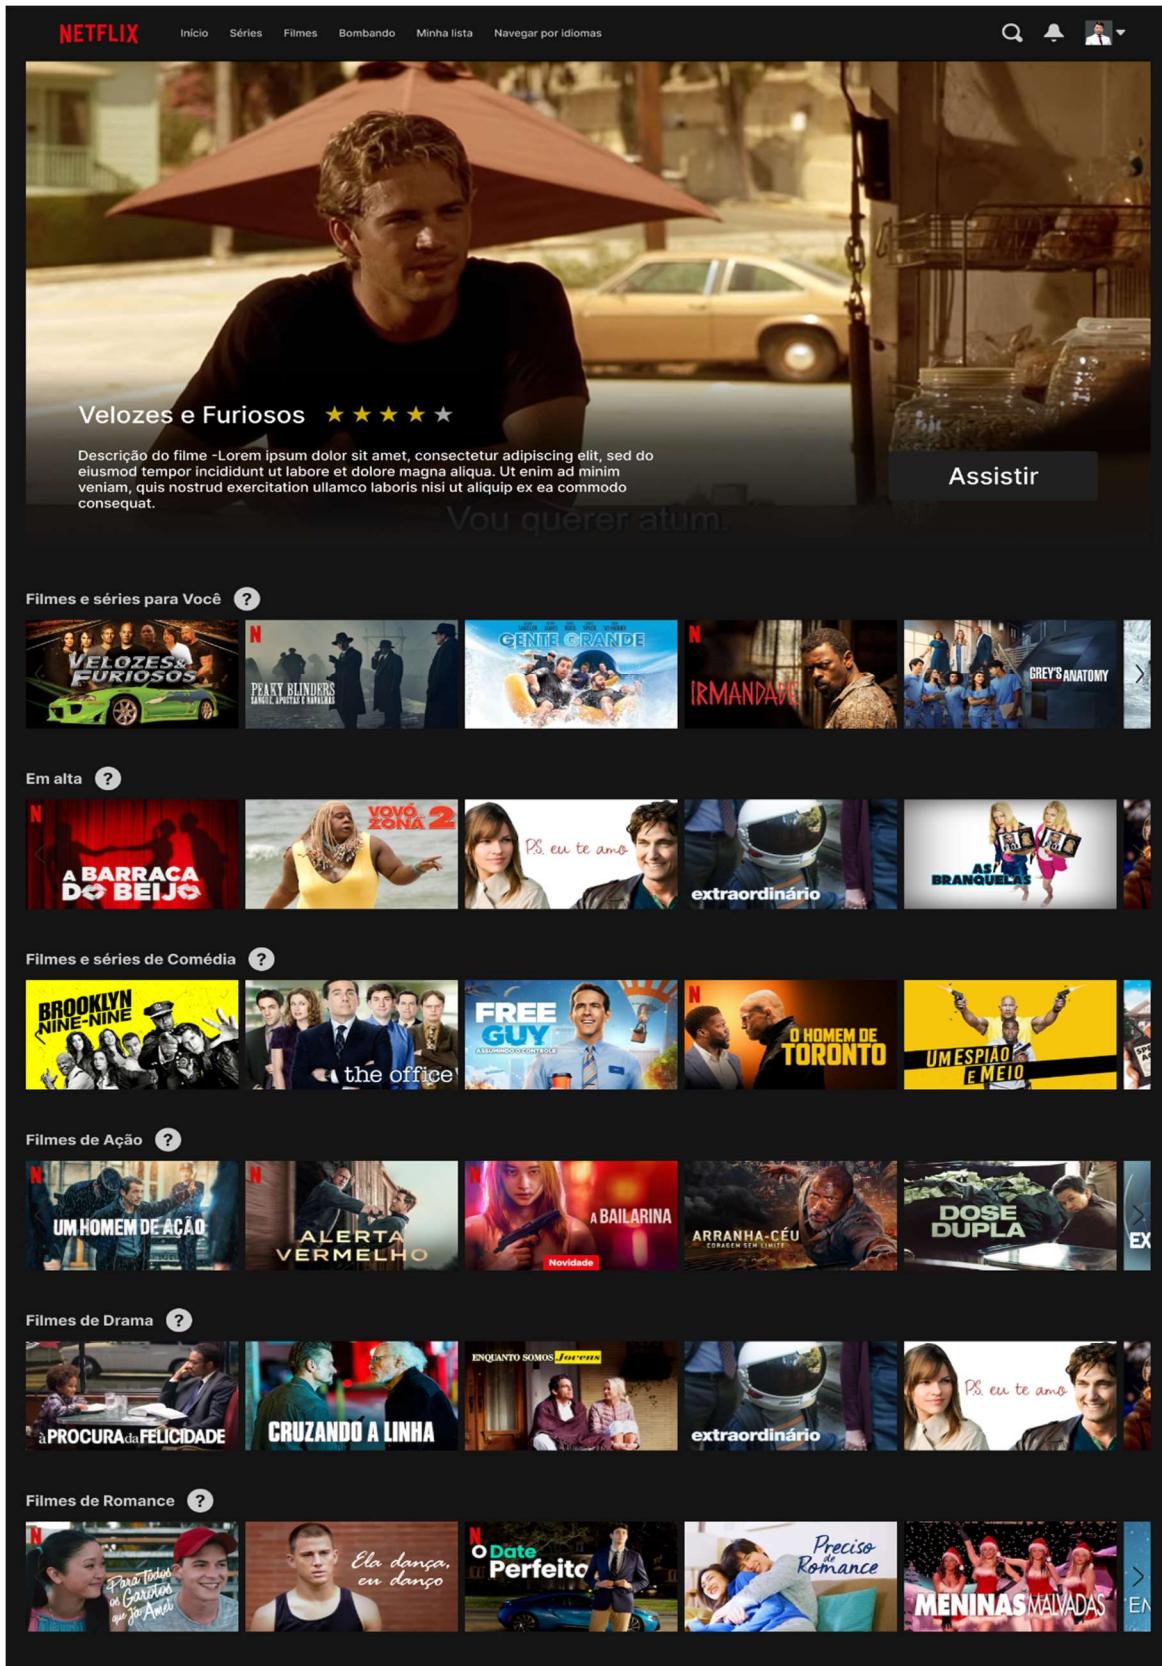
Fonte: Projeto pessoal.

Figura 15. Protótipo de baixa fidelidade - Recomendações personalizadas



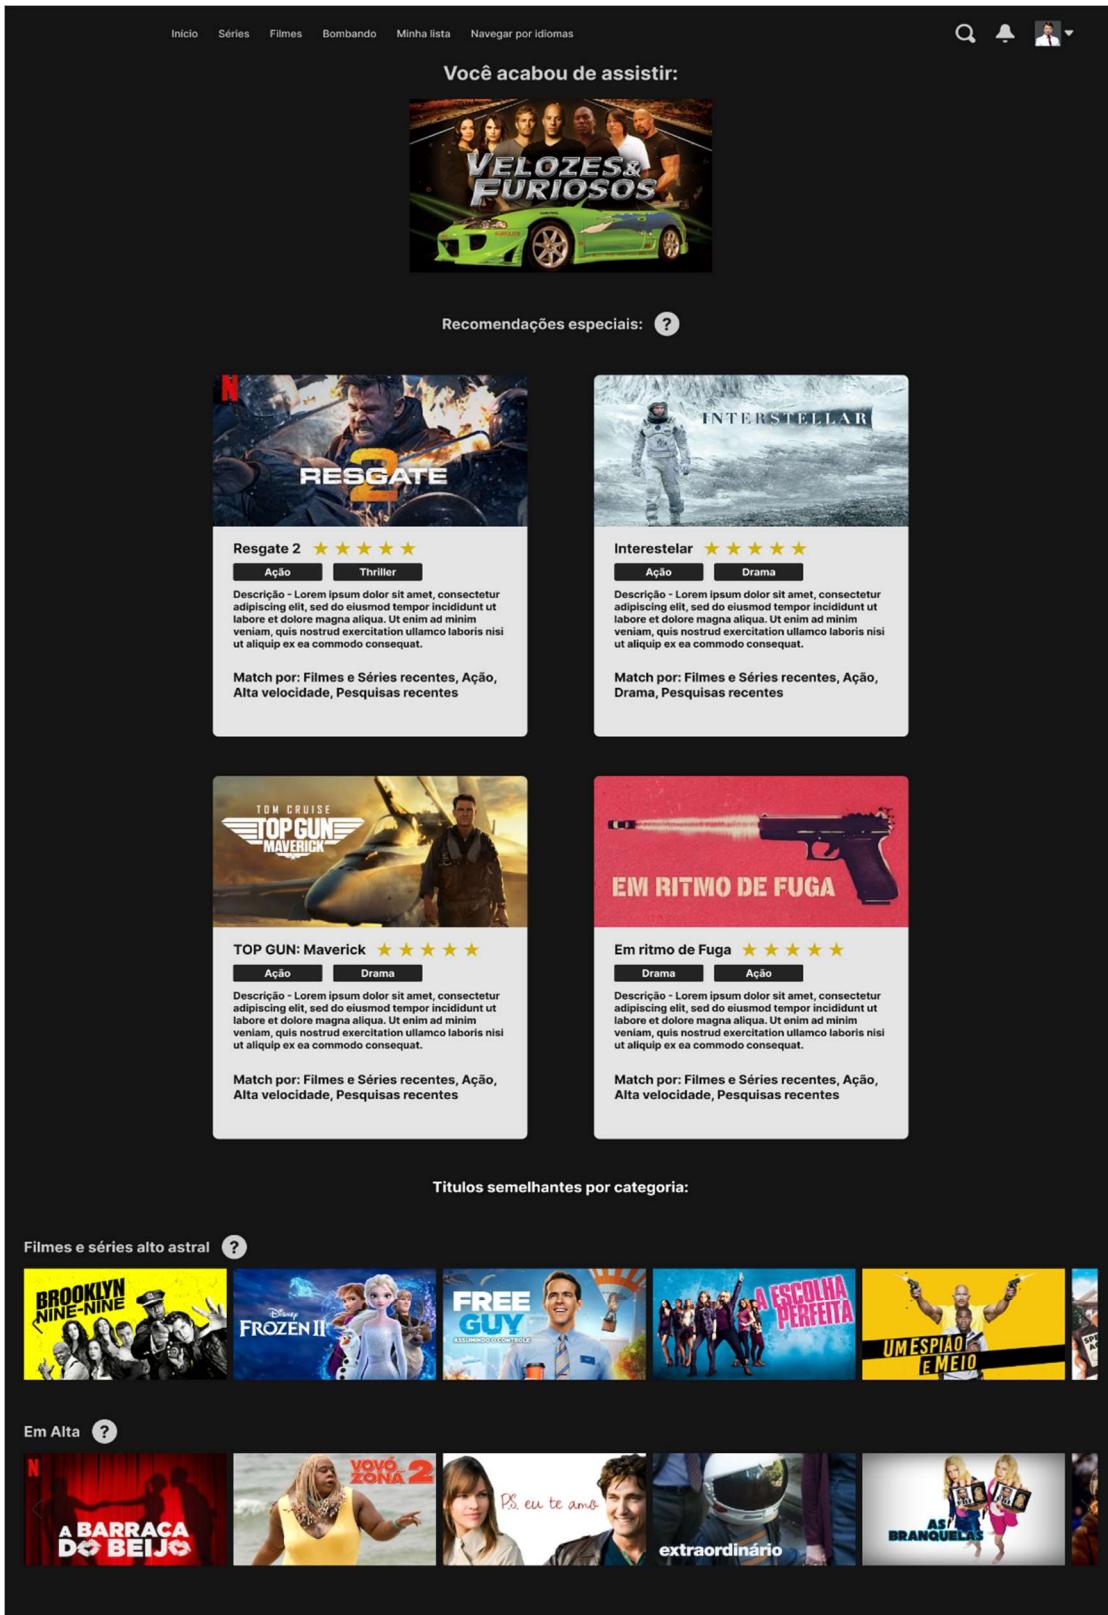
Fonte: Projeto pessoal.

Figura 16. Protótipo de média fidelidade - Tela inicial



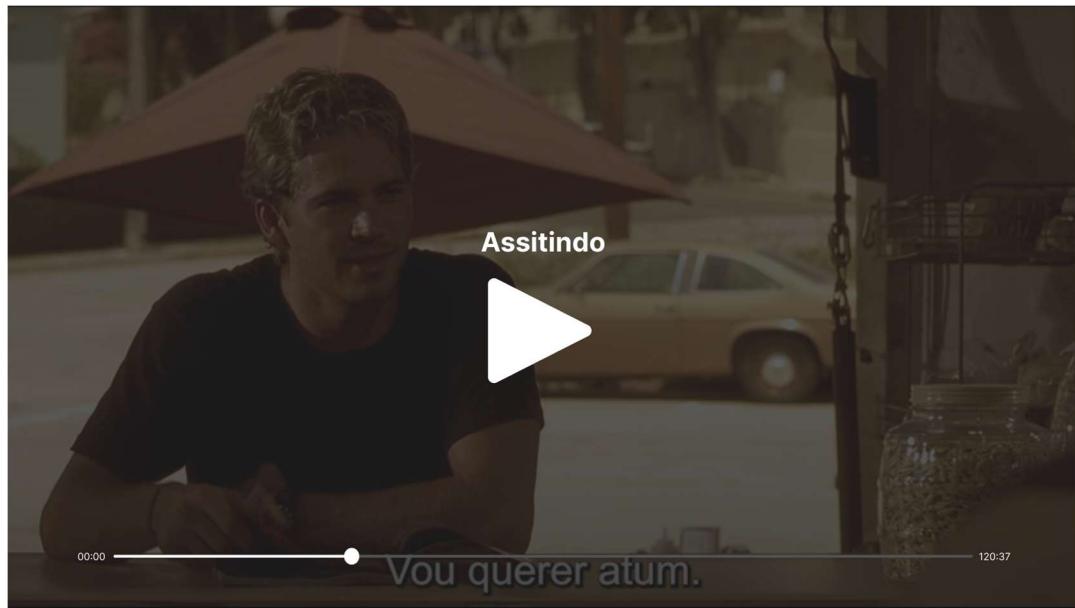
Fonte: Projeto pessoal.

Figura 17. Protótipo de média fidelidade - Recomendações personalizadas



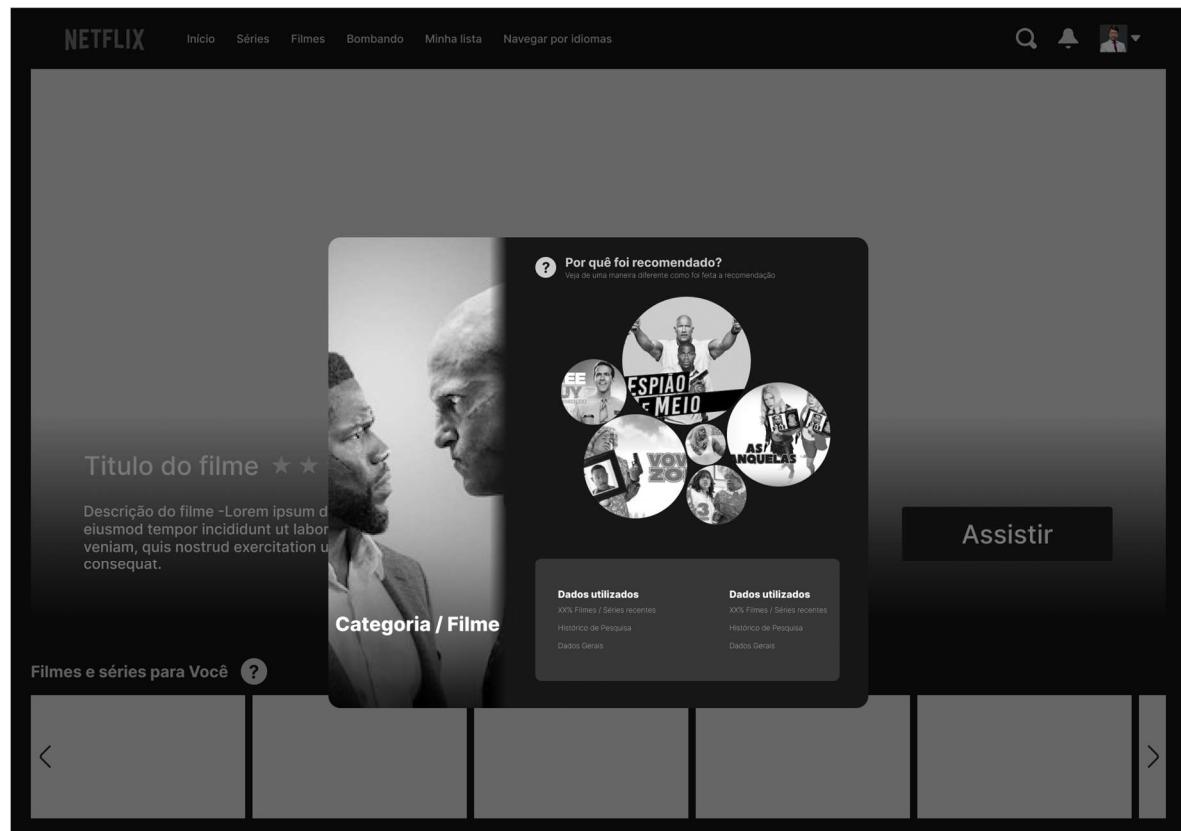
Fonte: Projeto pessoal.

Figura 18. Protótipo de média fidelidade - Player de conteúdos



Fonte: Projeto pessoal.

Figura 19. Protótipo de baixa fidelidade - Ideação de nova funcionalidade de recomendação.



Fonte: Projeto pessoal.

5.2.1. Pesquisa Qualitativa

A partir da conclusão do protótipo de média fidelidade, demos início às entrevistas.

Primeiro, os participantes responderam a um formulário que relatou os perfis como consumidores da plataforma. Tais respostas buscaram substituir a função de um sistema de recomendação ideal ao analisar e descrever os entrevistados, partindo de perguntas simples como “Quais são seus gêneros preferidos”, até perguntas mais complexas que abordam o entendimento dos entrevistados a respeito do uso de seus dados.

Com a conclusão dessa etapa, partimos para análise da interação adaptada à cada participante, seguido da segunda entrevista (como consta no apêndice 8.2), onde obtivemos os seguintes resultados:

5.2.1.1. Beatriz

Durante o teste, Beatriz demonstrou habilidade na navegação e no cumprimento dos objetivos estabelecidos. Ela não enfrentou nenhuma dificuldade nas tarefas, que incluíam a escolha de seu filme favorito dentro da categoria "Filmes e séries para você", a exploração da funcionalidade Bastidores (botão "?"), e a exploração da funcionalidade de Recomendações especiais.

Quando questionada sobre a assertividade das recomendações, Beatriz mencionou que todas as recomendações foram precisas, embora tenha observado que considerou invasivo o uso de seus dados sem aviso prévio.

Os conteúdos apresentados por meio das recomendações capturaram o interesse de Beatriz, demonstrando que a abordagem atual é eficaz.

A forma como as informações foram apresentadas influenciou um pouco nas escolhas futuras de conteúdo de Beatriz. Ela ressaltou que, se os dados coletados a constrangesse ou colocasse em uma posição que pudesse reforçar um padrão, suas escolhas provavelmente mudariam.

A apresentação transparente dos dados foi apreciada por Beatriz, pois a ajudou a entender por que as recomendações foram feitas e aliviou algumas preocupações

Pontifícia Universidade Católica de São Paulo

em relação à privacidade. Ela sugeriu que os dados relacionados ao tempo de tela, preferências de gênero e repetição de cenas pudessem ser apresentados de forma mais descontraída, sem constranger o usuário.

A forma atual de apresentação de dados não afetou negativamente a experiência de Beatriz na plataforma de streaming.

No que diz respeito à funcionalidade Bastidores, Beatriz expressou a opinião de que mostrá-la em todas as categorias é muito genérico. Ela sugeriu que talvez fosse mais interessante limitar a exibição dos Bastidores apenas nas recomendações essenciais.

5.2.1.2. Vitor

Vitor é um jovem de 20 anos que utiliza plataformas de streaming recorrentemente. Ele demonstrou interesse principalmente em conteúdos relacionados à ação, comédia e ficção científica.

Na entrevista, Vitor considerou as recomendações como assertivas e mencionou que algumas das recomendações realmente cativaram seu interesse por alguns instantes.

A apresentação das informações influenciou sua escolha de conteúdos futuros. A maneira como os dados foram apresentados fez sentido para ele e o incentivou a decidir assistir filmes que se encaixavam com seu gosto.

Ao apresentar um protótipo com funcionalidades relacionadas à transparência de dados, Vitor destacou que a clareza das informações, incluindo recursos visuais como círculos, ajudou a entender por que determinados conteúdos eram recomendados.

Ele expressou preocupações anteriores com a privacidade de dados, questionando de onde os dados são obtidos e por que certas recomendações são feitas. No entanto, a visualização de dados no protótipo supriu algumas dessas preocupações e lhe proporcionou mais segurança em relação ao uso de seus dados para melhorar as recomendações.

A experiência com a melhor apresentação dos dados não atrapalhou sua experiência na plataforma, pelo contrário, ele acredita que isso adiciona valor à experiência geral.

Vitor sugeriu melhorias, como se ater em recomendar filmes novos e diferentes, evitando recomendar filmes que o usuário já assistiu (como ocorrido). Ele também mencionou a possibilidade de adicionar interações sociais, como *watch parties*, na funcionalidade Bastidores, para gamificar perfis de contas e exibir dados sobre as interações entre amigos.

5.2.1.3. Adriana

A terceira pessoa entrevistada, Adriana, é uma mulher de 51 anos que utiliza plataformas de *streaming* baixa frequência (de uma a duas vezes por mês), demonstrou interesse principalmente em conteúdos relacionados a comédia romântica, dramas e filmes evangélicos.

Adriana não enfrentou dificuldades verdadeiramente significativas durante a realização das tarefas propostas no teste, incluindo a escolha de seu filme favorito dentro da categoria "Filmes e séries para você", a exploração da funcionalidade Bastidores (botão "?"), e a exploração da funcionalidade de Recomendações especiais.

Quando questionada sobre a assertividade das recomendações, Adriana expressou que, embora não tenha clareza sobre como as recomendações são geradas, ela costuma encontrar conteúdos de seu interesse.

Adriana não demonstrou um interesse particular na forma como os dados são apresentados ou utilizados para fazer as recomendações. Sua prioridade é simplesmente encontrar conteúdos que correspondam às suas preferências. No entanto, ela expressou que ficou interessada nas novas funcionalidades, indicando que as melhorias na experiência do usuário são bem-vindas.

No que diz respeito à funcionalidade Bastidores, Adriana não fez observações específicas, sugerindo que, dada a sua natureza ocasional de uso da plataforma, talvez ela não venha explorar profundamente tal funcionalidade.

Em resumo, Adriana demonstrou ser uma usuária de streaming que valoriza a simplicidade e a conveniência na escolha de conteúdos, e está aberta a melhorias que facilitem esse processo. Ela não demonstra preocupação com a coleta de dados, desde que sua experiência geral seja agradável e atenda às suas preferências.

5.2.2. Concepção

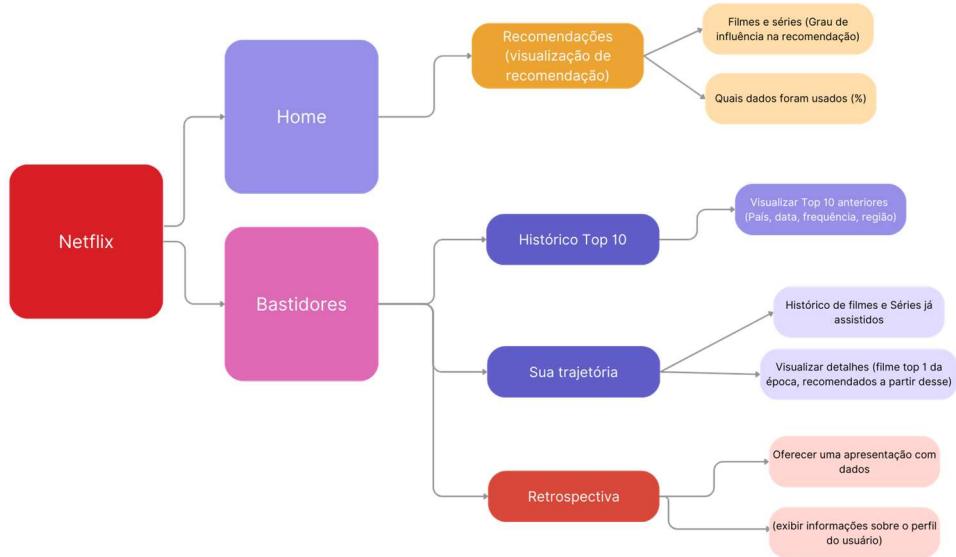
Com base nos resultados da pesquisa realizada, idealizamos como projeto final a aplicação de novas funcionalidades informacionais e interativas vinculadas aos sistemas de recomendação de plataformas de serviço de streaming, a exemplo da Netflix. Como citado anteriormente na ideação, iniciamos o desenvolvimento de um protótipo de alta fidelidade da interface proposta, com o objetivo de proporcionar aos usuários uma experiência exclusiva a respeito da fácil e didática visualização de dados.

Nossa solução demanda fornecer ferramentas que entendemos como necessárias para compreensão e acompanhamento da coleta e uso dos dados em tais plataformas. Visando simultaneamente agregar na funcionalidade e na experiência regular do aplicativo em questão.

Sendo assim, também é de nosso interesse analisar se a apresentação dos dados proposta afeta positivamente na usabilidade do usuário. Assim como se há margem rentável de tal aplicação, em busca de consolidar a proposta nas mais diversas plataformas do ramo.

A princípio, elaboramos um fluxo de telas onde é possível entender por quais caminhos o usuário irá percorrer dentro da nossa funcionalidade final em particular.

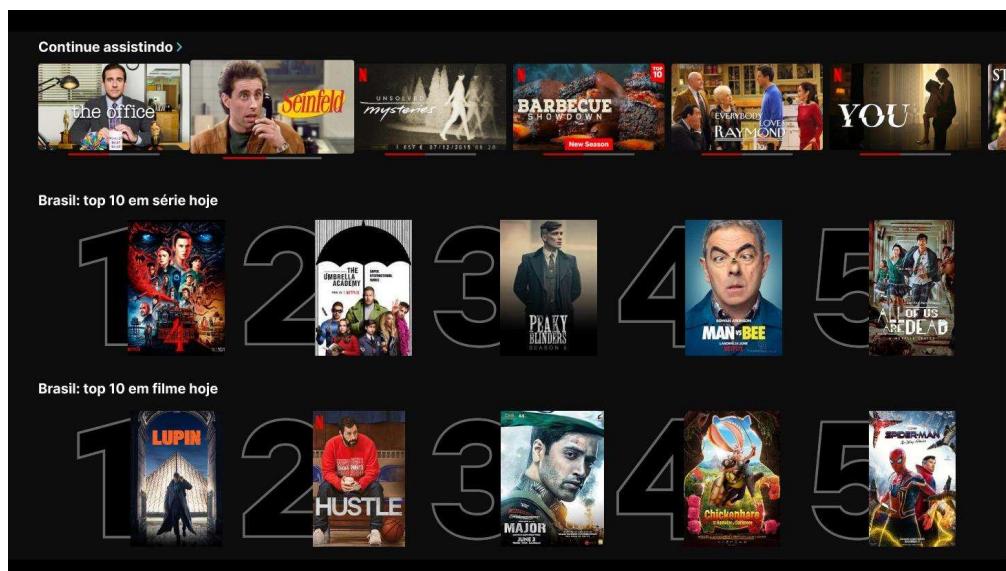
Figura 20. Planejamento do fluxo de telas.

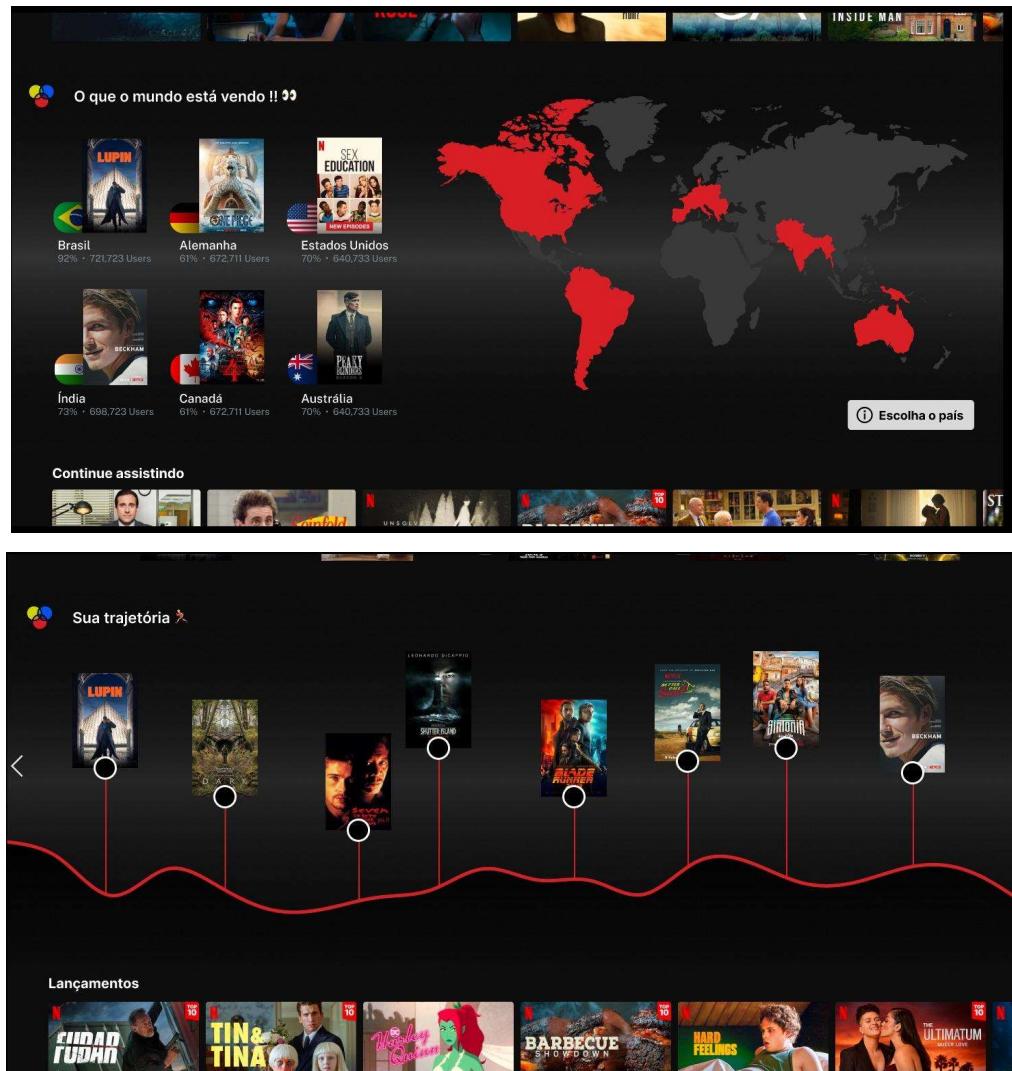


Fonte: Projeto pessoal.

Em seguida demos início ao protótipo modelo, buscando efetivar a concepção das novas funcionalidades abordadas nos protótipos anteriores.

Figura 21 - 23. Primeira versão do protótipo modelo.





Fonte: Projeto pessoal.

5.3. RESULTADOS

Compondo a identidade visual da plataforma, utilizamos os elementos visuais característicos da Netflix, como a paleta de cores, ícones e tipografia já empregada pela empresa. No entanto, adicionamos novos elementos e tonalidades que fazem sentido para a implementação da nova funcionalidade comentada.

O novo recurso central foi intitulado como “Bastidores”, que remete ao “ver por trás das cortinas”. Por meio dele, o usuário poderá acompanhar todas as atividades relacionadas às recomendações individuais, obter informações sobre seus dados e também comparar com os outros perfis da mesma conta. Coisas essas que normalmente não são reveladas ao usuário final.

Pontifícia Universidade Católica de São Paulo

Figura 24. Identidade Visual adaptada.



Fonte: Projeto pessoal.

Na identidade visual, foi utilizada a fonte Netflix Sans, com variações Light, Medium, Regular e Bold. Ambas são as oficialmente utilizadas no site e nas plataformas da Netflix, assim como o logo e os elementos gráficos acima ilustrados.

Para o logotipo da funcionalidade, tivemos forte inspiração do Diagrama de Venn, que é uma representação gráfica usada para mostrar a relação entre conjunto e que serve para ilustrar a relação entre diferentes grupos de elementos, relacionando a conexão com a troca dos dados entre plataforma-usuário. A fonte utilizada na tipografia foi a Poppins.

Já sobre as cores novas, nos inspiramos no evento da própria empresa chamado “Tudum”. Que anualmente ganha destaque por tentar modernizar a marca. Configuramos essa identidade para a funcionalidade a fim de trazer algo de novo e inspirador, visando a atração dos consumidores alvo.

Figura 25. Identidade Visual adaptada.



Fonte: Disponível em: <www.netflix.com/tudum/tudum-brazil-2023>. Acesso em: 31 out; 2023.

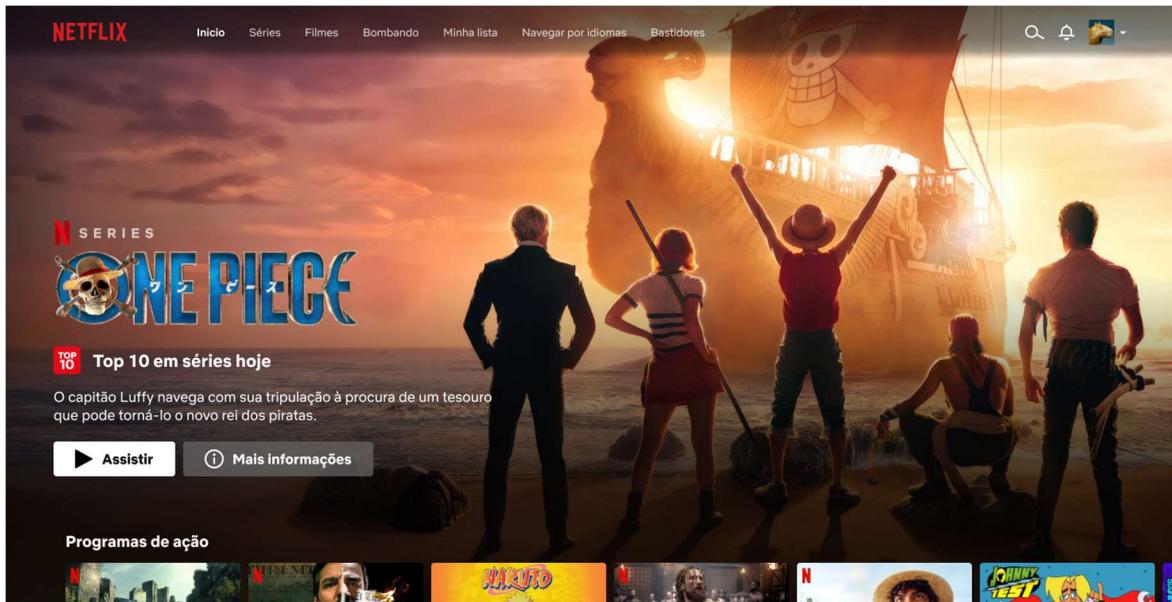
Sobre a tela inicial, mantivemos o mesmo padrão já encontrado no acesso atual à plataforma, permitindo a escolha do usuário entre os perfis já existentes antes mesmo de acessar o *landing page*.

Figura 26. Landing page do Protótipo Modelo.



Fonte: Projeto pessoal.

Figura 27. Página Principal do Protótipo Modelo.

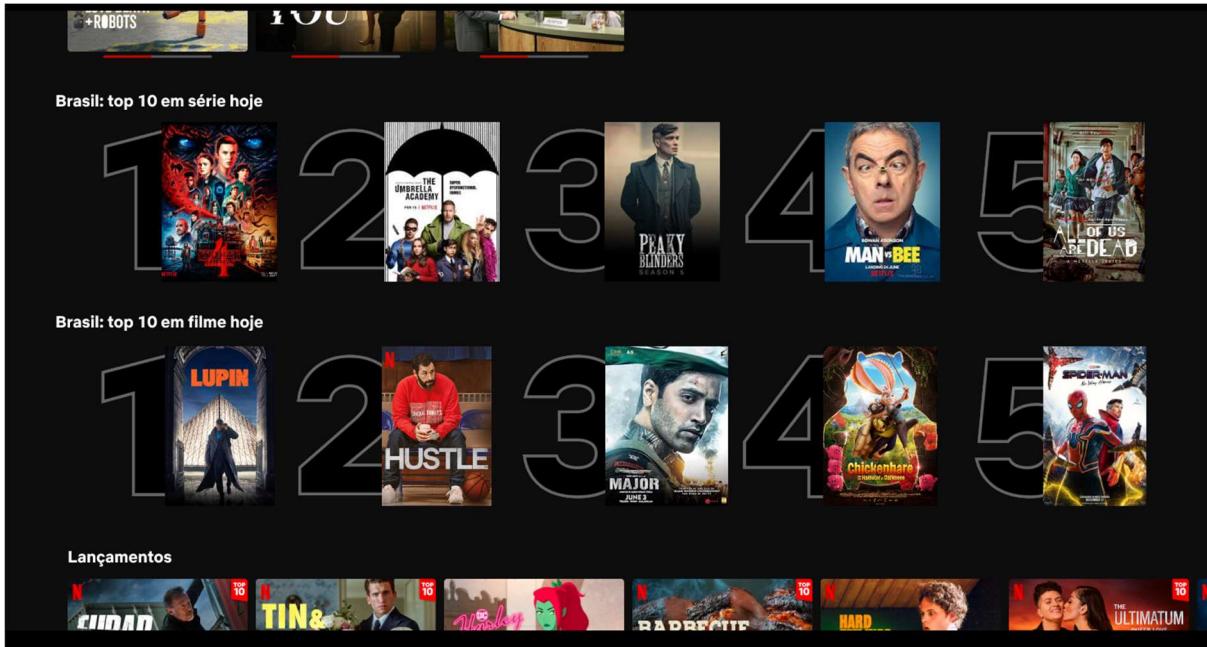


Fonte: Projeto pessoal.

Assim que o usuário acessar a plataforma, uma gama de filmes e séries estarão disponíveis para o usuário assistir, listados por tópicos que serão sugeridos pelo sistema de recomendação da plataforma. Dando prioridade a suas atividades anteriores.

"Top 10 Brasil", "Para Você" e "Programas para toda a família" são alguns exemplos dos tópicos que serão exibidos. Ainda, na barra superior da tela, algumas janelas poderão ser acessadas, como: Séries, Filmes, Minha lista, e a nova funcionalidade chamada "Bastidores".

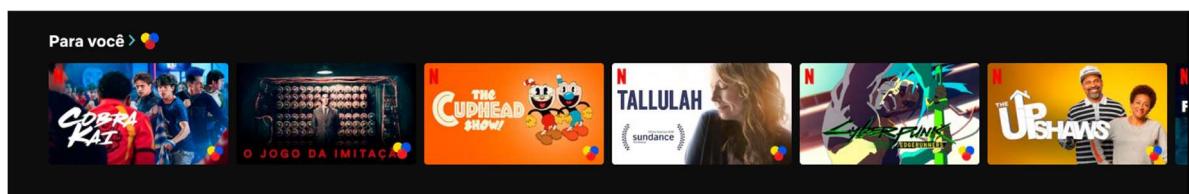
Figura 28. Lista de “Top 10 filmes e séries”.



Fonte: Projeto pessoal.

Como primeira proposta de funcionalidade de visualização de dados de fato, desenvolvemos uma variação no tópico “Pra você”, em que estarão disponíveis para o usuário filmes e séries que foram recomendados com base no que foi assistido anteriormente pelo mesmo. O tópico estará marcado com o logo dos Bastidores.

Figura 29. Nova Funcionalidade na aba “Para você”.



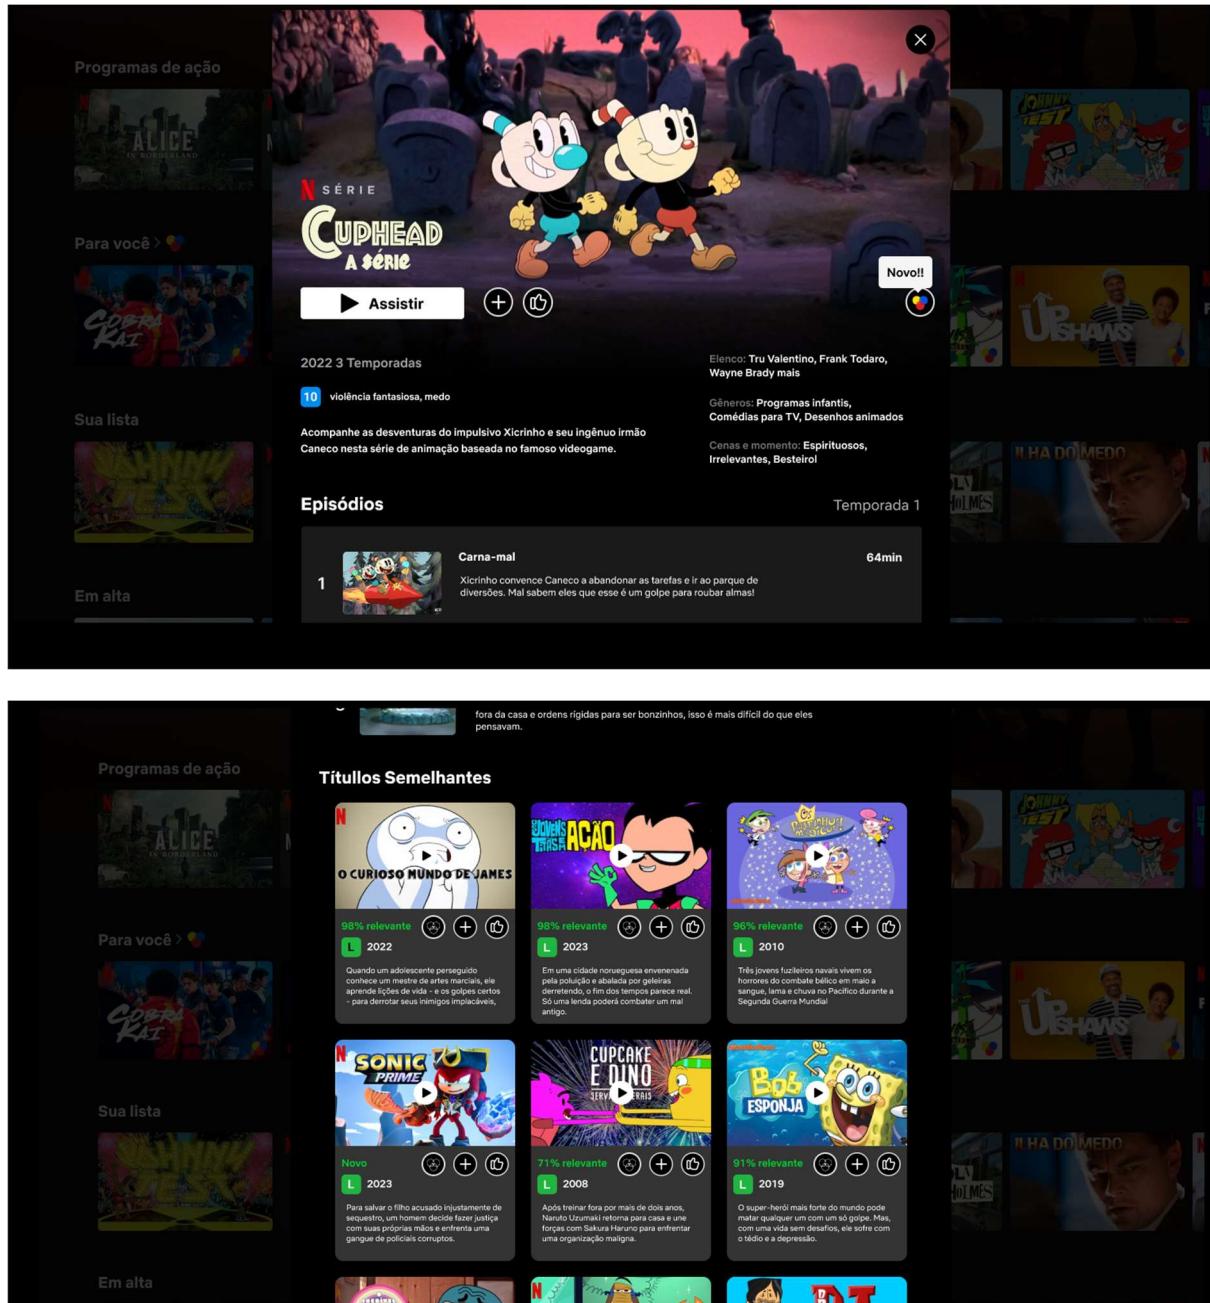
Fonte: Projeto pessoal.

O usuário, quando interagir com algum conteúdo de sua escolha, irá para uma aba contendo mais informações sobre o filme ou série em questão. Tópicos como sinopse, elenco, gênero, classificação indicativa e recomendações básicas, que são comuns a tal tela, se mantiveram.

Porém, com o foco na funcionalidade de visualização de dados, uma nova opção se dispõe nesta mesma aba, possibilitando àqueles usuários que gostariam de acompanhar seus dados a compreender o que realmente está sendo recomendado,

como foi selecionado tal processo. Revelando de maneira mais abrangente a seleção de conteúdos associados ao título.

Figura 30 e 31. Seleção de conteúdo.



Fonte: Projeto pessoal.

Ao acessar a nova funcionalidade, o usuário terá uma maneira visual de como foi realizada a recomendação do filme ou série que visa assistir. Na parte superior da

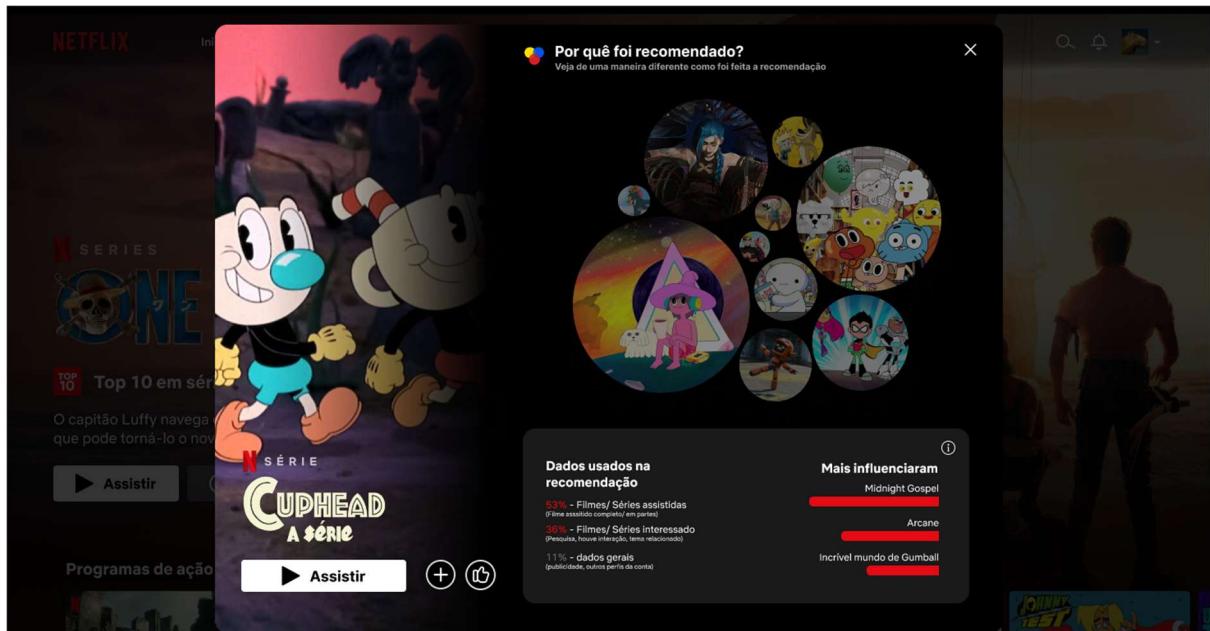
tela, utilizamos as figuras das obras em formato circular, para representar quais delas foram mais ou menos influentes na recomendação requerente.

Demonstra-se, os títulos em destaque como de maior influência (assistidos recentemente, mais pesquisado, tendências regionais) e os pouco destacados com menor influência (associados por alguma interação ou pesquisa já realizada, ou baseada em dados externos à plataforma).

Esse layout foi projetado dessa maneira a fim de inovar na apresentação de relevância conteudística, sem gerar estranhamento ao usuário.

Além disso, na parte inferior da página, conterá um relatório geral feito a partir das obras destacadas, mostrando quais dados foram utilizados na recomendação (Obras assistidas, pesquisa da série, gênero, tipo de animação, publicidades acessadas pelo usuário, influência de outros perfis, etc).

Figura 32. Aba “Bastidores” na Seleção de Conteúdo.



Fonte: Projeto pessoal.

A segunda área vigente da nova funcionalidade proposta é a própria aba dos Bastidores, onde o usuário vai encontrar diferentes alternativas de ver tanto os próprios dados comparadas a outros perfis da conta, quanto uma área que aborda tópicos e destaques globais.

Selecionando a partir da tela inicial, na parte superior, onde estão as outras opções fixas. Em “Bastidores”, o usuário é diretamente direcionado a apresentação que introduz a nova função da plataforma (caso o usuário não deseje assistir, é possível pular a introdução).

Figura 33. Tela de apresentação dos “Bastidores”.



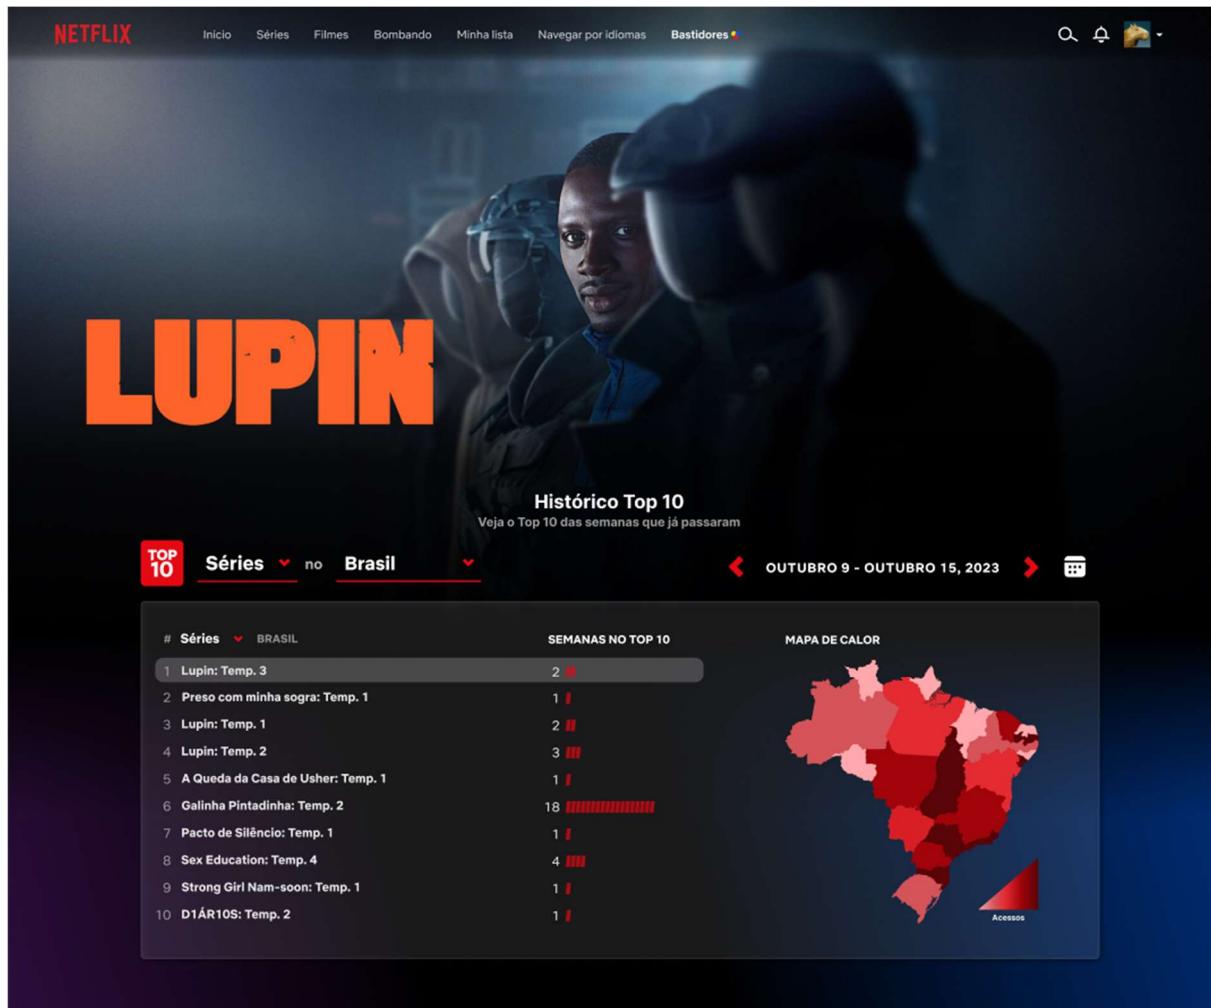
Fonte: Projeto pessoal.

Na aba Bastidores, os usuários encontraram algumas funcionalidades que exploram a questão de visualização de dados de maneira inovadora e eficiente. Dentre essas *features*, está o “Histórico de Top 10”, que consiste na possibilidade do cliente explorar os filmes e séries que estavam em alta tendência no mundo e regionalmente. Catalogado semanalmente, destaca-se o período que as obras ficaram em alta, a partir de um mapa de calor que mostra por região o fluxo de visualizações dos usuários do país.

Outra funcionalidade disponível é a “Sua trajetória”, onde o usuário poderá visualizar todos os seus títulos assistidos desde seus primeiros dias de uso. Além de evidenciar novamente as tendências, servindo como um histórico funcional e rentável, gerando um fluxo de continuidade.

Por fim, apresentaremos a “Retrospectiva”, que trará para o usuário uma maneira criativa e visualmente intuitiva, de seus dados passados, em comparação aos outros perfis da mesma conta, recapitulando a trajetória anual do usuário.

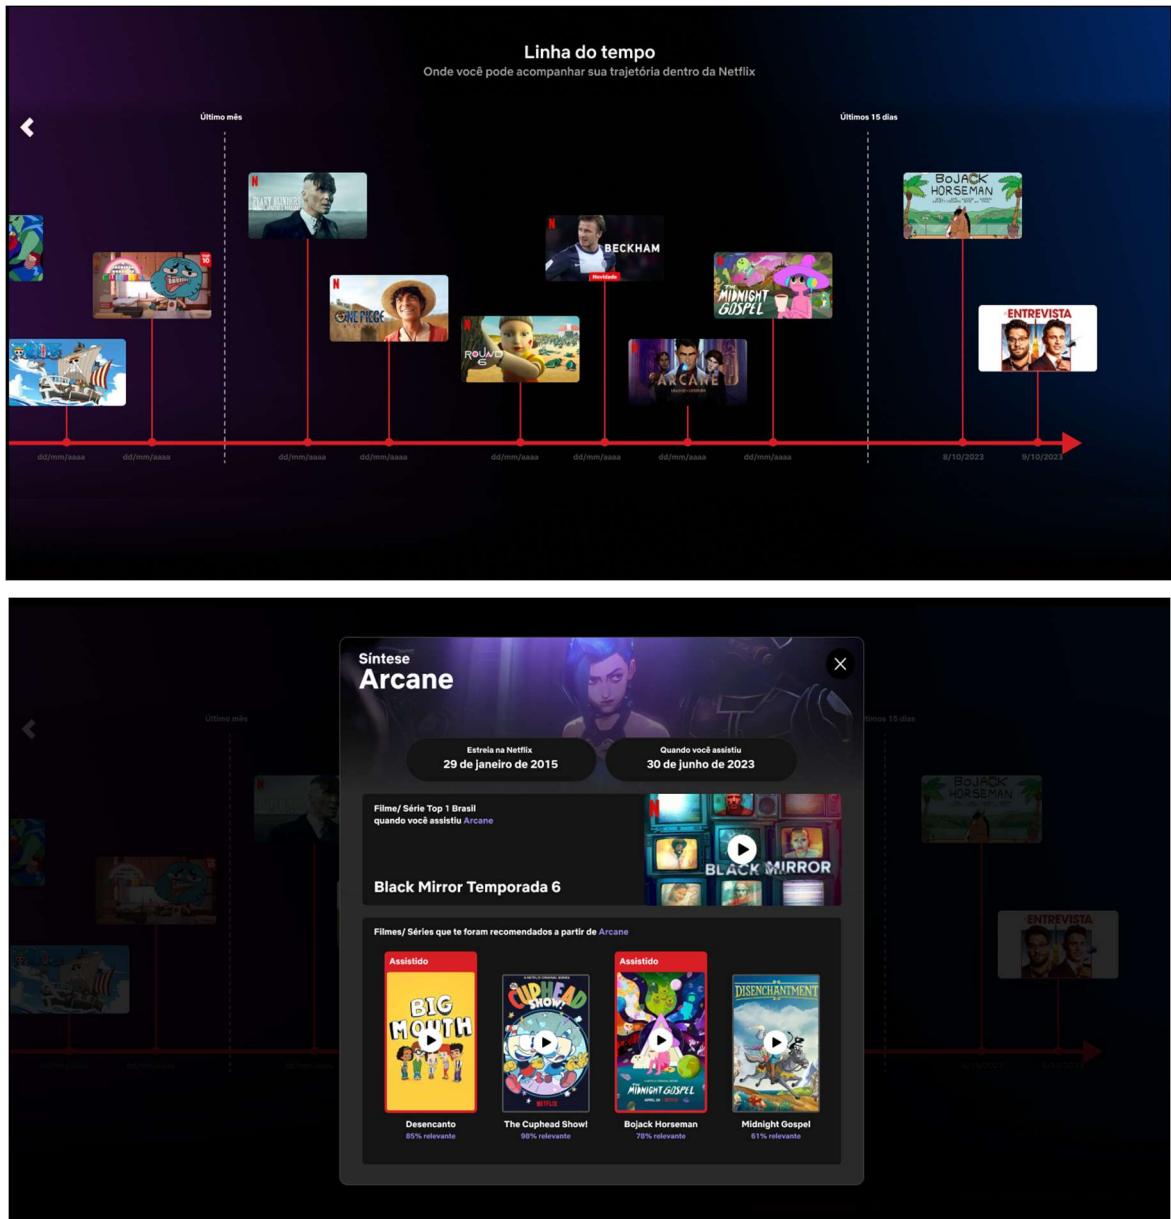
Figura 34. Tela inicial dos “Bastidores”.



Fonte: Projeto pessoal.

De acordo com o tópico “Sua trajetória”, assim como já comentado anteriormente, será onde os usuários conseguirão acompanhar o histórico de filmes e séries assistidos durante o uso integral da plataforma. Além disso, salientamos a relevância, no momento em que o conteúdo foi consumido. Somado a isso, reforçamos a demanda de títulos recomendados ao usuário.

Figura 35 e 36. Funcionalidade Linha do Tempo.



Fonte: Projeto pessoal.

Por fim, propomos como terceira e última funcionalidade, a “Retrospectiva”. Que serão painéis personalizados, que mostram um resumo de atividades na plataforma, recapitulando a trajetória anual do usuário e comparando-a com o desempenho dos outros perfis da conta e usuários regionais.

Dados como gêneros preferidos, atores e diretores mais assistidos, horas totais de consumo e comparação “gamificada” de temas com outros perfis, são principais informações dispostas nesses painéis exibidos ao usuário.

Figura 37 - 39. Funcionalidade Retrospectiva.





Fonte: Projeto pessoal.

6. CONSIDERAÇÕES FINAIS

O objetivo geral do presente trabalho consistiu em analisar sobre a relevância da aplicação de um Design Informativo de excelência, sob gestão de plataformas digitais. Tendo em vista a pergunta de como tais métodos de visualização de dados influenciam na usabilidade e na experiência do usuário aplicado em sistemas de recomendação em serviços *online de streaming*. A este respeito, buscou-se ainda trazer resultados praticados por empresas em plataformas virtuais.

Para tanto, foi desenvolvida uma pesquisa teórica. No referencial teórico, foram abordados os temas que abrangem os sistemas de recomendação, assim como sobre os aprendizados de *machine learning* e métodos de filtragem provenientes dessa técnica. Verificando-se que com o decorrer do tempo, a filtragem colaborativa com base em conteúdo sugere produtos relevantes, personalizados e atrativos a cada usuário, com base em seu respectivo histórico de uso e preferências.

Como resposta à pergunta proposta e ao objetivo de pesquisa, tem-se que com a finalidade de eficiência na recomendação e transparência informacional, o uso do Design Interativo vinculado a usabilidade, mostram-se uma ferramenta de extrema importância para os negócios de empresas, a exemplo de serviços de streaming e *e-commerce*, contribuindo para uma boa retenção de público.

Portanto, há exemplos já praticados que demonstram, a exemplo da Spotify e Netflix, ser a filtragem de similaridade uma excelente ferramenta, pois permite que as respectivas plataformas criem perfis de usuários individuais com base nos dados coletados. Isto faz com que, se torne mais preciso, conforme o tempo de uso e o conhecimento das escolhas e padrões de gostos de seus usuários.

Apesar disso, não se pode olvidar a preocupação com a privacidade das informações dos usuários. Dada a oclusão e omissão das plataformas que detém domínio do mercado. Portanto, o Design Informacional deve prevalecer na tomada de decisões morais.

Diante disso, para se analisar o comportamento e interações do usuário na plataforma, as empresas devem identificar padrões de preferências individuais, para informar dados coletados sem prejudicar o funcionamento ideal da plataforma. Isto é,

inserindo referências personalizadas que auxiliem na escolha de conteúdos, visibilidade do histórico, compartilhamento e até mesmo em destaques da própria plataforma.

Assim sendo, a exemplo do Spotify e Netflix, o uso harmônico entre visualização de dados e inteligências de sugestões conteudísticas, permite criar usuários fiéis a partir da promoção dos dados coletados. Sugestões para pesquisas futuras envolvem comparar novas aplicabilidades baseadas no estudo educacional e informativo do Design, visando a clareza dos materiais referentes a cada consumidor final.

7. REFERÊNCIAS BIBLIOGRÁFICAS

AGNER, L. **Ergodesign e arquitetura da informação: trabalhando com o usuário**. Editora Quartet, 2012.

ALEXEI, V.; RODRIGUES, R.; CRISTINA, E. **Usabilidade: um estudo de prática da arquitetura da informação em website**. UFMG, 2021. Disponível em: <<https://periodicos.ufmg.br/index.php/moci/article/view/37261/29003>>. Acesso em: 3 ago. 2023.

ARAÚJO, M. **Métodos de clustering em aprendizado de máquinas não supervisionado** / Marlon Vinícius Alves de Araújo; Karina Yuriko Yaginuma, orientadora. UFF, 2021.

BRASIL, InfoQ. **Sistemas de Recomendação sem enrolação - Gabriel Moreira**. 2019. Disponível em <<https://www.youtube.com/watch?v=thDmbYBCU7c&t=1393s>>. Acesso em: 18 jun. 2023.

CHEESEMAN, P.; STUTZ, J.; SELF, M.; KELLY, J.; YALOR, W.; FREEMAN, D. **Bayesian classification**. In: **Proceedings of the Seventh National Conference of Artificial Intelligence (AAAI-88)**, St. Paul, MN, 1990.

DAVI, A. **O que fazem os sistemas de recomendação?** Disponível em: <<https://www.linkedin.com/pulse/o-que-fazem-os-sistemas-de-recomenda%C3%A7%C3%A3o-antonio-david-viniski/>>. Acesso em: 03 ago. 2023.

DEMARCO, M.; DOS SANTOS, G. **Mecanismos de recomendação no Spotify: uma análise dos elementos que configuram a sugestão de conteúdos musicais na atual interface da plataforma**. UFPB, 2021. Disponível em: <<https://periodicos.ufpb.br/ojs2/index.php/cm/article/view/58936>>. Acesso em: 17 jun. 2023.

FARIA, E. **Aula 3 - Tópicos Especiais em Computação: Agrupamento de Dados Representação dos Dados**. FACOM, 2020.

FERRARELI, C. PINHEIRO, C. CHERUTTI, M. **Plataformas de streaming e o seu sistema de recomendação “personalizado”: um caso sobre o Spotify**. Grupo de Trabalho: CONSUMO E CULTURA. Universidade Feevale/RS, 2020.

FIGUEIREDO, C.; BARBOSA, R. **Spotify e construção do gosto: uma breve análise sobre a oferta de playlists pela plataforma**. Signos do Consumo, São Paulo, v. 11, n. 2, p. 28-39, jul./dez. 2019.

FONTES, J. A. **Abordagens de seleção de variáveis para classificação e regressão em dados espectrais para controle da qualidade**. UFRGS, Programa de pós-graduação em Engenharia de produção, 2020.

FRY, B. **Visualizing Data: Exploring and Explaining Data with the Processing Environment**. Editora: Andy Oram, 2008. Acesso em: 18 ago. 2023.

GANESAN, S. **Determinants of Long-Term Orientation in Buyer-Seller Relationships**. Journal of Marketing, v. 58. 1994.

KAHNEMAN, D. *et al. Prospect Theory: An Analysis of Decision under Risk*. THE ECONOMETRIC SOCIETY, v.47. 1979.

MAMEDE, M. **A História do Spotify**, 2023. Disponível em: <<https://www.showmetech.com.br/historia-do-spotify/>>. Acesso em: 5 jun. 2023.

MITCHELL, T. **Machine Learning**, Editora McGraw-Hill Science/Engineering/Math, 1997.

NIELSEN, J. **The Myth of the Genius Designer**. Nielsen Norman Group, 2007. Disponível em: <<https://www.nngroup.com/articles/the-myth-of-the-genius-designer/>>. Acesso em: 28 mai. 2023.

NG, Andrew. **Machine Learning Yearning is a deeplearning.ai Project**. Deep Learning.ai, 2018.

NORMAN, D. **O Design do Dia-a-dia**. Editora Anfiteatro, Tradução Ana Deiró, 2018.

OLIVEIRA, A. **Comportamento de consumidores de serviços de streaming: um estudo de caso de usuários da Netflix no Brasil e em Portugal**. P. Porto, 2019. Disponível em: <<http://hdl.handle.net/10400.22/15124>>. Acesso em: 17 jun. 2023.

OLIVEIRA, Danielle Sales. **Sistema de recomendação baseado em filtragem colaborativa em uma base de dados de feedback implícito**. UFP, 2019. Disponível em: <https://www.cin.ufpe.br/~tg/2019-1/TG_CC/tg_dso.pdf>. Acesso em: 17 jun. 2023.

PASSOS, Jaire Ederson. **Metodologia para o design de interface de ambiente virtual centrado no usuário**. Dissertação (mestrado). UFRGS, Escola de Engenharia e Faculdade de Arquitetura, Programa de Pós-Graduação em Design, 2010.

REZENDE, S. **Sistemas inteligentes: fundamentos e aplicações (2003)**. Editora: Manole, ICMC .2003.

RIBEIRO, D. **Visualização de dados na Internet**. Mestrado em tecnologias da inteligência e Design digital, PUC-SP, 2009. Acesso em: 13 jun. 2023.

RICCI, F.; ROKACH, L.; SHAPIRA, B. **Recommender Systems Handbook**. 2011. 35p. Disponível em: <https://www.researchgate.net/publication/227268858_Recommender_Systems_Handbook>. Acesso em: 17 jun. 2023.

RIVEROS, Lilian Jeannette Meyer; SECCO, André Luiz; FERNÁNDES, Carlos Manuel Reyes. **Assistente virtual inteligente para a integração e gerenciamento de dispositivos IoT**. Anuário Pesquisa e Extensão Unoesc Videira, v. 2, p. e15225-e15225, 2017.

ROLIM, V. **Client profile prediction using convolutional neural networks for efficient recommendation systems in the context of smart factories**. Disponível em: <https://www.researchgate.net/figure/Figura-1-Exemplo-de-um-Sistema-de-recomendacao-usando-filtragem-baseada-em-conteudo-22_fig1_320993342>. Acesso em: 03 ago. 2023.

ROSA, E. **Sistemas de informação e aplicações computacionais**. Editora Atena, 2020.

SILVA, G. **Avaliação entre algoritmos de filtragem colaborativa baseada em vizinhança e transferência de conhecimento para CD-CARS**. UFRP, 2019.

SOUSA, G. **Fundamentos Básicos do Machine Learning que você Precisa Saber**. Disponível em: <<https://www.learningdata.dev/post/fundamentos-basicos-do-machine-learning-que-voce-precisa-saber>>. Acesso em: 03 ago. 2023.

SOUZA, Antonio Carlos de et al. **Proposta de um processo de avaliação da usabilidade de interfaces gráficas de sistemas interativos computacionais, através da integração das técnicas prospectiva, analítica e empírica**. UFSC, 2004.

UNIÃO BRASILEIRA DE COMPOSITORES. **Spotify surpreende e fecha 2022 com 205 milhões de assinantes** (2023). Disponível em: <[https://www.ubc.org.br/publicacoes/noticia/21216/spotify-surpreende-e-fecha-2022-com-205-milhoes-de-assinantes#:~:text=Spotify%20surpreende%20e%20fecha%202022,2023\)%20%2D%20Uni%C3%A3o%20Brasileira%20de%20Compositores](https://www.ubc.org.br/publicacoes/noticia/21216/spotify-surpreende-e-fecha-2022-com-205-milhoes-de-assinantes#:~:text=Spotify%20surpreende%20e%20fecha%202022,2023)%20%2D%20Uni%C3%A3o%20Brasileira%20de%20Compositores)>. Acesso em: 18 jun. 2023.

VERHALEN, A. et al. **O controle por detrás da tela: a Inteligência artificial da NetFlix sob a óptica dos usuários**. Anais Estendidos do XVIII Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais, SBC, 2019.

VIJAYSINH, L. **Cold-Start Problem in Recommender Systems and its Mitigation Techniques**. Analytics India Magazine. Disponível em: Cold-Start Problem in Recommender Systems and its Mitigation Techniques. <<https://analyticsindiamag.com/cold-start-problem-in-recommender-systems-and-its-mitigation-techniques/>>. Acesso em: 17 jun. 2023.

YASUOKA, R. **Recomendações algorítmicas: percepções de consumo na plataforma de streaming Netflix**. [s.l.: s.n.]. Universidade Estadual Paulista Faculdade de Arquitetura, Artes, Comunicação e Design Programa de Pós-graduação em Mídia e Tecnologia Mestrado Profissional, 2023. Disponível em: <<https://repositorio.unesp.br/server/api/core/bitstreams/121f7df1-84f1-486d-9e03-53fcfd8b265/content>>. Acesso em: 31 out. 2023.

8. APÊNDICES

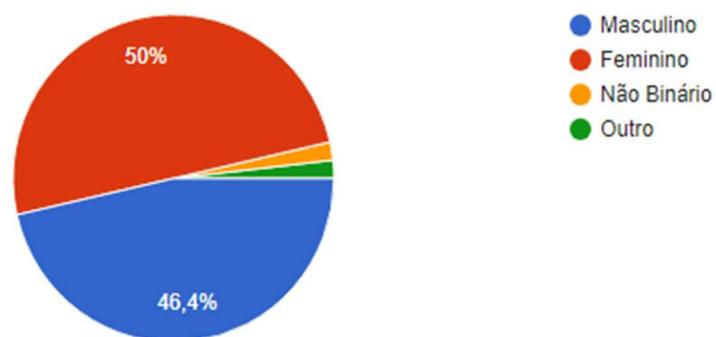
8.1. PESQUISA QUANTITATIVA

Para entender a relação dos entrevistados com seus próprios dados (que são coletados por plataformas de serviço de streaming), realizamos um questionário online contendo 15 perguntas direcionadas ao assunto. As quais foram respondidas por 62 indivíduos, sendo o público majoritariamente do sexo feminino (50%) e de faixa etária entre 15 a 24 anos (62,5%).

Figura 40 e 41. Pesquisa - Gênero e idade.

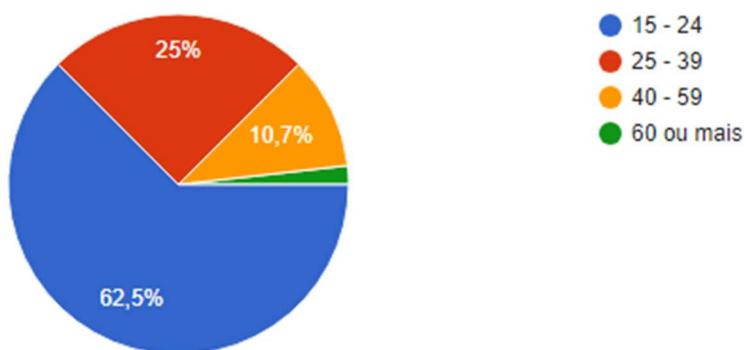
Qual gênero você se identifica?

56 respostas



Quantos anos você tem?

56 respostas



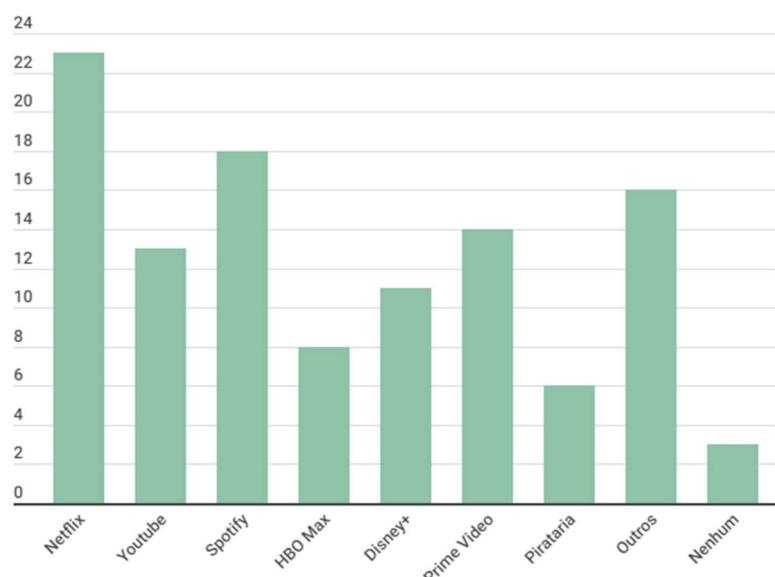
Fonte: Projeto pessoal.

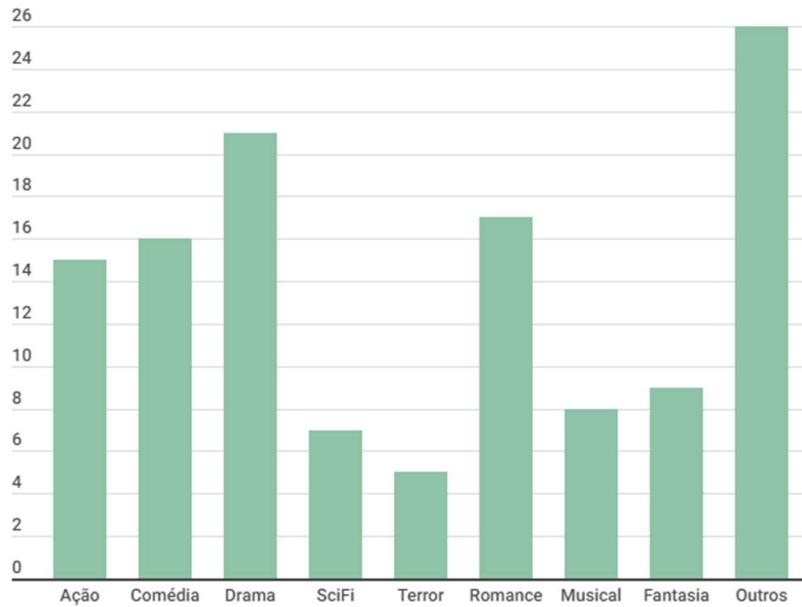
A fim de compreender as qualificações e possíveis limitações no conhecimento de nossos entrevistados, resolvemos questionar a área de atuação / estudo dos entrevistados.

- I. 21% são de áreas relacionadas às Artes Visuais (como o próprio Design)
- II. 19% estudam ou atuam na área da Saúde (como Medicina, Nutrição e Fisioterapia)
- III. 11% são da área de Relações Internacionais
- IV. 23% trabalham ou estudam áreas relacionadas à Tecnologias
- V. 12% estudam ou atuam em áreas atreladas Educação
- VI. 8% aparentam ser empreendedores ou microempresários
- VII. 14% estudam, atuam ou têm interesse em outras áreas.

As próximas duas perguntas a seguir são a respeito de quais plataformas de streaming mais são utilizadas pelos entrevistados, e quais são os conteúdos consumidos nos mesmos. Olhando as respostas vemos que aproximadamente 37% dos entrevistados (23 pessoas) utilizam da maior plataforma de streaming por assinatura atual, a Netflix. Dentre outros resultados.

Figura 42 e 43. Pesquisa - Plataformas e Gêneros de maior consumo.



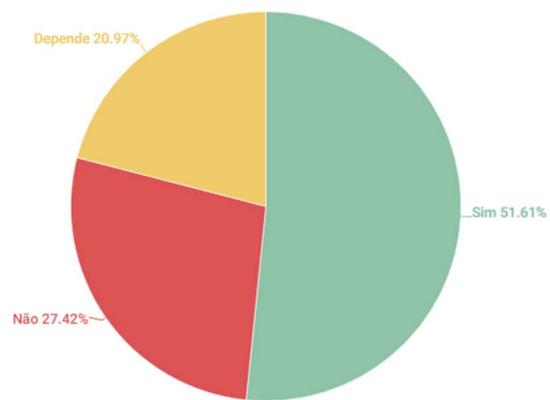


Fonte: Projeto pessoal.

Agora, envolvendo a questão das sugestões e recomendações de conteúdo propostas por tais plataformas, questionamos se o entrevistado consome conteúdos além do que apenas lhe é recomendado. E este foi o resultado:

Figura 44. Pesquisa - Recomendação externa à plataforma.

Exploram além do que é recomendado

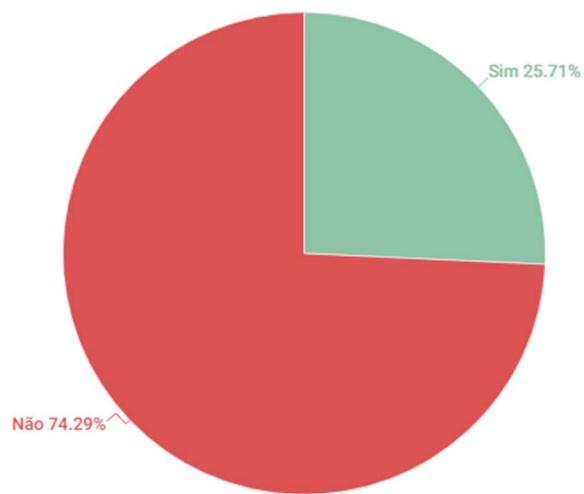


Fonte: Projeto pessoal.

A seguir iniciamos indagações que abordam o uso e o gerenciamento dos dados coletados por essas empresas, fornecedoras de serviços de streaming. Primeiro questionamos se é de conhecimento dos entrevistados quais dados são usados para a recomendação de conteúdos. Os resultados mostram uma notória desinformação dos usuários.

Figura 45. Pesquisa - Conhecimento individual sobre dados.

Acham que sabem quais dados são usados em recomendações



Fonte: Projeto pessoal.

Em seguida, perguntamos “Você acha que as políticas de privacidade das plataformas de streaming são claras suficientes sobre os dados que foram/serão usados?” e este foi o resultado:

Figura 46. Pesquisa - Transparência das políticas de privacidade.



Fonte: Projeto pessoal.

Subsequentemente, perguntamos:

“Você se sente bem informado sobre essa questão? Você sente que tem controle sobre mudanças sobre tal consentimento já aprovado?”

Figura 47. Pesquisa - Avaliação de conhecimento.



Fonte: Projeto pessoal.

À medida que as perguntas foram “modelando” o raciocínio dos entrevistados, buscamos uma resposta mais precisa sobre o que foi pressuposto pelo tema até então. Inquirimos quais tipos de informações eles acham que são coletados por plataformas de streaming. E o resultado é impressionante:

- I. 56,4% dos participantes citaram dados cadastrais, como: Nome, gênero, idade, etc.

- II. 43,5% citaram dados pessoais, como: Endereços de email, localização, contatos.
- III. 27,3% comentaram sobre os históricos, como de pesquisa e visualização.
- IV. 20,9% acreditam que é coletado o tempo de tela / conteúdo consumido.
- V. 37% comentaram de características do conteúdo consumido (ex.: gênero, atores, dentre outros).
- VI. 24,9% transparecem que acreditam em algo além do tecnológico. A exemplo, teorias da conspiração.
- VII. 17,9% admitem não ter ideia de como e quais dados são coletados.

Buscando o enredo da pesquisa, fizemos questionamentos sobre uma proposta de melhor visualização dos dados coletados, aos usuários...

A fins de compreensão de privacidade e informação pessoal.

- I. 62,9% responderam que possuem interesse.
- II. 24,2% não se interessam.
- III. 12,9% não possuem uma opinião formada.

A fins de auxiliar na escolha de conteúdos.

- I. 37,2% responderam que contribuíram na escolha.
- II. 45,1% responderam que não auxiliaria ou que não faria diferença.
- III. 17,7% não possuem uma opinião formada.

Por fim, perguntamos “Quais dados você gostaria de ter acesso ou que fosse mais fácil acessar?”

- I. 26% gostariam de acessar o máximo de informação possível
- II. 12% desejam apenas evitar spam.
- III. 32% não fazem questão de serem informados.
- IV. 23% não possuem conhecimento suficiente para afirmar quais dados com precisão.
- V. 7% possuem opiniões divergentes.

8.2. PESQUISA QUALITATIVA

As respostas relatadas neste apêndice são as questões destaque referentes apenas das entrevistas pós-interação do protótipo de média fidelidade, que foi adaptado ao perfil de cada participante.

1. As recomendações sugeridas foram assertivas quanto ao seu perfil?
 - a. P1: Todas as recomendações foram assertivas, apesar de ter achado meio invasivo utilizar meus dados dentro do protótipo sem avisar previamente;
 - b. P2: Sim, corresponderam perfeitamente ao meu perfil;
 - c. P3: Confesso que na verdade, eu não prestei tanta atenção nas recomendações, mas tinha alguns filmes que eu gosto sim.
2. Quais conteúdos recomendados realmente cativaram o seu interesse?
 - a. P1: Todos, realmente está de acordo com meu perfil;
 - b. P2: Interestelar e Top Gun Maverick. Agora os outros, mesmo que estejam de acordo com meu perfil, já os conhecia ou já tinha assistido;
 - c. P3: Gosto de filmes mais leves, normalmente qualquer filme que me faça rir, ou algo evangélico já me agrada.
3. A apresentação das informações influenciou na escolha de um possível consumo futuro dos conteúdos do tipo?
 - a. P1: Talvez, não costumo assistir algo só porque apareceu na tela, mas alguns títulos me interessaram sim.;
 - b. P2: Acho que sim, pois da maneira que foi mostrado, me influenciou a assistir filmes que fazem sentido com meu gosto;
 - c. P3: Não tanto. Assim, não foi um diferencial. Mas normalmente assisto o que me agrada mesmo.

Neste momento foi apresentado o protótipo modelo, revelando outras novas funcionalidades e aplicações relacionadas à transparência de dados também adaptados ao usuário final. Logo após foi questionado:

4. A clareza das informações apresentadas ajuda a entender por que determinados conteúdos são recomendados?
 - a. P1: Sim. Ajuda a entender o porque as coisas foram recomendadas, e alivia algumas preocupações sobre não saber exatamente quais dados são recolhidos;
 - b. P2: Ajudou sim no meu entendimento das recomendações, principalmente nos recursos utilizados, como por exemplo os círculos;
 - c. P3: Sim, gostei bastante de saber de onde vem as coisas que assisto.
5. A visualização de dados no protótipo abordou ou aliviou algumas das suas preocupações?
 - a. P1: Sim, como eu disse, tira um pouco a preocupação de não entender a fundo o uso dos meus dados;
 - b. P2: Com uma melhor visualização de dados, melhorou um pouco em saber o porquê de determinadas recomendações, e passando uma segurança maior do que realmente eles estão fazendo com os dados, para melhorar a recomendação em si;
 - c. P3: Gostei, achei útil. Mas pessoalmente não é algo que me interesse tanto, no caso de ficar correndo atrás, sabe?
6. Essa melhor apresentação do que é coletado pelas plataformas atrapalha a sua experiência com o conteúdo?
 - a. P1: Do jeito que foi apresentada, nem um pouco;
 - b. P2: Não atrapalha em nada e até melhora na experiência da plataforma, adicionando novas coisas e não só sendo um catálogo;
 - c. P3: Eu não acho que me atrapalharia. Na verdade, talvez nem fosse perceber.

7. Possui alguma sugestão ou melhorias que você acredita que poderia aumentar a privacidade ou a transparência no sistema de recomendação apresentado?

- a. P1: Acho que principalmente esses dados de “tempo de tela, clicar mais em thumbs com X gênero ou repetir X cena mais vezes”, deveriam ser apresentados de forma humorada e sem constranger o usuário.

Agora sobre os “Bastidores” acho que mostrar em todas as categorias fica muito abrangente, sugiro mostrar só as recomendações essenciais. Talvez fique mais interessante;

- b. P2: Sugestão, sempre recomendar filmes novos, e diferentes, não mostrando filmes que você já assistiu.

Na aba de bastidores, colocar uma interação entre amigos, como uma *watchparty*, e mostrar dados sobre essa relação, gamificando não só os perfis de uma conta mas diferentes contas;

- c. P3: Sem sugestões. Gostei do jeito que vocês esclareceram alguns pontos sobre privacidade e tudo mais. Acho que outras pessoas iam gostar também.