



**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE COMUNICAÇÃO
CURSO DE COMUNICAÇÃO ORGANIZACIONAL**

NATALIA GUARANY BONETTI

**EFEITOS DOS ALGORITMOS DE PERSONALIZAÇÃO EM
PLATAFORMAS DE VÍDEO ONLINE**

Brasília, DF

2019

Natalia Guarany Bonetti

**EFEITOS DOS ALGORITMOS DE PERSONALIZAÇÃO EM
PLATAFORMAS DE VÍDEO ONLINE**

Trabalho de Conclusão de Curso apresentado a Faculdade de Comunicação da Universidade de Brasília como parte das exigências para a obtenção do título de Bacharel em Comunicação Organizacional.

Orientador: Sivaldo Pereira da Silva

BRASÍLIA, DF

2019

AGRADECIMENTOS

Gostaria de começar agradecendo aos meus pais que sempre me ensinaram a valorizar a educação e que acreditaram que a aprendizagem me levaria longe. Além disso, queria os reconhecer por serem meu ponto de apoio quando preciso de um sábio conselho. A minha mãe por ter me apresentado ao curso que hoje me graduo e ao meu pai por me ensinar que na vida poucas pessoas irão lhe estender a mão e por isso ser autodidata é tão importante. A minha irmã quero agradecer por ser minha melhor amiga, pela nossa parceria e por estar dividindo esse momento tão importante da vida comigo, uma vez que estamos nos graduando ao mesmo tempo. Gostaria de agradecer a Suellen, pelo carinho e por me tratar como família me ajudando a formatar e finalizar com chave de ouro esse documento, e ao meu companheiro Osmar que me apoiou em todos os momentos difíceis durante a escrita desse trabalho, que me lembra todos os dias o quanto eu sou capaz, que desperta em mim meu lado mais sonhador e corajoso, obrigada por nunca faltar comigo, por ser atencioso e delicado tanto nos momentos de alegria quanto nos momentos de dificuldades. Muito obrigada a todos vocês.

Gostaria de agradecer ao Movimento Empresa Júnior por me ensinar que nós não podemos mudar o mundo, mas podemos mudar as pessoas e assim elas poderão mudar o mundo, e mudar pessoas está diretamente ligado a dar educação e conhecimento a elas, e por meio deste movimento pude ter contato com os ambientes mais inovadores e empreendedores que já pertenci, e assim eu fui mudada. Obrigada também a Concentro por me dar o ano mais louco da minha vida, por me ensinar a não ter medo de errar e ter a ousadia de agir. Por me ensinar a ser persistente, mesmo em momentos de incapacidade, por ser destemida e me mostrar que eu sou capaz de fazer o que quiser, obrigada por me dar a oportunidade de ter feito a diferença na vida de mais de 1600 empresários e estudantes, ajudando-os a serem sua melhor versão, a versão Alto Impacto.

A frase “quem tem amigos, tem tudo” nunca fez tanto sentido para mim. A este TCC devo milhares de agradecimentos a amigos que me ajudaram muito dando suporte emocional durante o processo, mas principalmente a aqueles que colocaram a mão na massa e não mediram esforços para me ajudar a realizar minha meta, que era escrever um TCC em que me orgulhasse.

Sabia que não seria uma tarefa fácil unir comunicação, programação e estatística em um simples trabalho de conclusão de curso em comunicação organizacional, pois pouco se vê dentro do nosso curso pessoas partindo para análises quantitativas. Sendo assim, quero agradecer ao Murilo Botelho e ao Victor Matheus, que me ajudaram fazendo o código do site com algoritmos de personalização, viabilizando meu experimento. A Victoria Lima tudo que posso sentir é gratidão por ter me ajudado e orientado, mesmo quando ela também não sabia quais eram os próximos passos, obrigada por me ensinar tanto e me ajudar a descobrir quais testes inferenciais estatísticos cabiam para analisar minhas respostas.

Por fim quero agradecer aos professores que sempre com muita generosidade transmitiram seu conhecimento e carinho. Porém, gostaria de agradecer mais especialmente a professora Elen, meu grande exemplo de mulher e professora, ao Polydoro, que em sua matéria descobri qual seria meu tema de pesquisa e que sempre foi um professor muito parceiro, ao Sivaldo por ter me apresentado ao mundo dos algoritmos e cruzamento de dados, além de ter me orientado no processo dessa monografia e finalmente a professora Carla que me acolheu durante o processo de escrita desse documento, pegou na minha mão e me mostrou o caminho, contigo aprendi que ser professor é uma constante doação e aprendizagem. Obrigada também Universidade de Brasília, por me mostrar que o mundo é muito maior do que meu próprio umbigo e que sair de dentro de nossas bolhas sociais é fundamental para o crescimento acadêmico e profissional.

RESUMO

O mercado está passando por diversas mudanças com a interferência das tecnologias. A Inteligência Artificial e Big Data são duas tecnologias que estão modificando a forma de se produzir e consumir entretenimento no mundo, pois ambas geram insumos para produzir e disseminar conteúdos em plataformas de maneira mais eficaz e assertiva para seu público. Essas transformações estão tornando cada vez mais competitivo o mercado e assim se aflorou a necessidade de diferenciação por parte das empresas. Uma estratégia para se diferenciar dos concorrentes é a utilização da personalização. Conteúdos já produzidos voltados para um mercado tem potencial de aceitação muito maior por parte dos telespectadores, dessa forma foram crescendo plataformas de *streaming* como o Youtube e a Netflix. Essas duas plataformas tem uma forte coisa em comum, algoritmos de personalização que estimulam o consumo de seus produtos. Com o intuito de checar a eficácia desses algoritmos, o presente estudo retrata um experimento realizado testando a experiência do usuário e a intenção de compra em três plataformas. A primeira plataforma sendo completamente não personalizada, a segunda personalizada de acordo com as maiores vendas de bilheterias e a terceira personalizada com os dados fornecidos pelos respondentes. O resultado obtido com o experimento foi que quanto mais personalizada a plataforma, melhor é a experiência do usuário, conseqüentemente aumentando a intenção de compra. Por fim, o estudo concluiu que a personalização é uma ferramenta fundamental no quesito diferenciação dentro das empresas e possui enorme potencial melhorando a imagem da marca e aumentando o fluxo de vendas.

Palavras-chave: Personalização. Plataformas de entretenimento em vídeo online. Algoritmos de personalização. Entretenimento. Inteligência Artificial. Big Data.

LISTA DE ILUSTRAÇÕES

Figura 1 – Modelo de perspectiva comportamental.....	16
Figura 2 – Gráfico sobre consumo de vídeos na web.....	21
Figura 3 – Gráfico comparativo de consumo entre plataformas de vídeo online	22
Figura 4 – Modelo de pesquisa	27

LISTA DE TABELAS

Tabela 1 –	Perfil da amostra	28
Tabela 2 –	Análise de distribuição de notas por plataforma.....	34
Tabela 3 –	Média das notas nas plataformas.....	35
Tabela 4 –	Análise de distribuição de votos por plataforma	36
Tabela 5 –	Análise descritiva de escolaridade em relação a preferência de compra.....	36
Tabela 6 –	Análise descritiva de gênero em relação a preferência de compra.....	37
Tabela 7 –	Análise descritiva de renda em relação a preferência de compra.....	38
Tabela 8 –	Análise descritiva do tempo dedicado ao Youtube em relação a preferência de compra.....	39
Tabela 9 –	Análise descritiva do tempo dedicado a Netflix em relação a preferência de compra.....	39
Tabela 10 –	Teste chi quadrado para independência com a VD intenção de compra.....	40
Tabela 11 –	Teste Shapiro-Wilk.....	42
Tabela 12	Teste de Friedman.....	43
Tabela 13 –	Teste de Wilcoxon pareado - Comparação de médias dois a dois.....	44
Tabela 14 –	Teste de Wilcoxon pareado - Percepção da experiência usuário antes e depois.....	45
Tabela 15 –	Teste de Friedman - Comparação de médias das plataformas.....	47
Tabela 16 –	Teste de Wilcoxon pareado - Grupo 1.....	48
Tabela 17 –	Teste de Wilcoxon pareado - Grupo 2.....	49
Tabela 18 –	Teste de Wilcoxon pareado - Grupo 3.....	50

LISTA DE ABREVIATURAS E SIGLAS

BPM	- <i>Behavioral Perspective Model</i>
OTT	- <i>Over-The-Top</i>
VD	- Variável Dependente
VI	- Variável Independente
VM	- Variável Moderadora
IA	- Inteligência Artificial
EUA	- Estados Unidos

SUMÁRIO

1 INTRODUÇÃO	10
1.1 CONTEXTUALIZAÇÃO	10
1.2 OBJETIVOS	12
1.2.1 Objetivo geral	12
1.2.2 Objetivos específicos	12
1.3 ESTRUTURA DO TRABALHO.....	13
2 AS MUDANÇAS NOS HÁBITOS DE CONSUMO DA POPULAÇÃO	14
2.1 COMPORTAMENTO DO CONSUMIDOR E O BEHAVIORAL PERSPECTIVE MODEL (BPM)	14
2.2 IMPLEMENTAÇÃO DA INTELIGÊNCIA ARTIFICIAL E BIG DATA NA DECISÃO DE COMPRA	17
2.3 EFEITOS DAS FERRAMENTAS DE PERSONALIZAÇÃO EM PLATAFORMAS ONLINE	22
3 MÉTODOS E TÉCNICAS DE PESQUISA DA FASE EXPERIMENTAL ..	26
3.1 DELINEAMENTO DE PESQUISA	26
3.2 VARIÁVEIS E MODELO DE PESQUISA	26
3.3 PERFIL E AMOSTRA DOS PARTICIPANTES	28
3.4 PROCEDIMENTOS DE COLETA E ANÁLISE DE DADOS	31
4 RESULTADOS E DISCUSSÃO DA FASE EXPERIMENTAL	34
4.1 ANÁLISES DESCRITIVAS DAS PLATAFORMAS	35

4.2 ANÁLISES DE ASSOCIAÇÃO DOS RESULTADOS EM RELAÇÃO A INTENÇÃO DE COMPRA	40
4.3 ANÁLISE DE RELAÇÃO ENTRE A NOTA DA EXPERIÊNCIA DO USUÁRIO E INTENÇÃO DE COMPRA	46
5 CONCLUSÃO	52
REFERÊNCIAS	55
APÊNDICE	58

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

O mundo já passou por diversas mudanças decorrentes das três revoluções industriais, a primeira revolução trouxe a mecanização para as indústrias, com a energia mecânica e máquinas a vapor. A segunda se destacou com a eletrificação da fábrica, pela utilização dos métodos científicos de produção culminando com a fábrica de produção em massa. A terceira revolução industrial inovou com a informatização (computadores mainframe, computadores pessoais e a internet) entrando na fábrica para automatizar tarefas mecânicas e repetitivas. Essas revoluções foram momentos históricos e geraram grandes marcos temporais no comportamento dos seres humanos, mudando tanto a forma de se produzir, como também consumir bens e serviços, alterando valores, tendências e hábitos da população (BRASIL, 2017).

A quarta revolução está começando um novo ciclo. Trata-se da invenção e implementação da Inteligência Artificial (IA) (KAGERMANN et al., 2013), momento que se caracteriza por: mudanças na capacidade de operações em tempo real, virtualização, descentralização, orientação a serviços e modularidade (HERMANN, 2015).

Esta revolução será marcada por um conjunto de tecnologias que permitem a simbiose do mundo físico, digital e biológico. Além disso, como consequências da mesma, pode-se destacar o alto foco na personalização de produtos para cada consumidor, uma vez que a digitalização influencia diretamente no alto volume de oferta de produtos, aumentando a competitividade do mercado, tornando mais desafiadora a venda para cada *target* (ROYER; SANTOS, 2010).

Porém, além da IA, outras tecnologias também estão ganhando força e contribuindo para o desenvolvimento dos negócios. A PricewaterhouseCoopers (PWC) realizou a 19ª Pesquisa Global de Entretenimento e Mídia 2018-2022 (PWC, 2019), por meio da qual colheu a percepção de diversas empresas ao redor do mundo com o intuito de testar mais de 150 tecnologias emergentes. Decorrente desta pesquisa, a PWC chegou às oito tecnologias principais para os novos negócios, sendo elas: a internet das coisas, realidade aumentada, realidade virtual, *blockchain*, impressora 3D, drones e robôs.

Todos os campos do mercado terão que se adequar às novas tendências que as tecnologias irão propor, e o Relatório Setorial de TIC 2019, produzido pela Associação Brasileira das Empresas de Tecnologia da Informação e Comunicação (BRASSCOM, 2019) prevê que até 2022 o investimento em tecnologias de transformação digital ficará na casa dos R\$ 345,5 bilhões de reais, ou seja, a previsão de acordo com a pesquisa é que os investimentos no setor de tecnologia alavanquem nos próximos anos, e as empresas que não se adequarem ficarão em desvantagem (BRASSCOM, 2019). Com o mercado de entretenimento e lazer não será diferente, como mostra a 19ª Pesquisa Global de Entretenimento e Mídia 2018-2022. De acordo com esta pesquisa, os gastos nas plataformas digitais apresentam crescimento mais acelerado que os demais, liderados por games, publicidade digital e Over-The-Top (OTT)¹ – vídeo na internet.

A Agência Nacional do Cinema (ANCINE) estima que a proporção de pessoas que acessam vídeos sob demanda via plataformas OTT, ao menos uma vez por dia tenha crescido de 30% para mais de 50% entre usuários de banda larga, entre 2010 e 2015 (BRASIL, 2018). Além disso, o tempo médio semanal em que as pessoas assistem a séries de TV, programas e filmes dobrou de 2011 a 2015. No Brasil, a penetração desses serviços é estimada em 49% em relação aos usuários de internet, o que coloca o país no mesmo patamar dos Estados Unidos (EUA), em relação a consumo de plataformas OTT, e acima de países como Canadá e México.

A pesquisa realizada pela Video Viewers, Provokers em 2018 (GOOGLE 2018) demonstra especificamente o crescimento do consumo de vídeos online no Brasil, chegando a uma curva exponencial de 135% em apenas quatro anos, enquanto a televisão cresceu apenas 13% durante esses mesmos anos.

Os dados apresentados revelam uma forte tendência para o mercado de entretenimento e mídia no mundo, incluindo o Brasil. Porém, apesar do forte crescimento da indústria, ainda existem poucas pesquisas buscando compreender o efeito da personalização de conteúdo nessas plataformas de *streaming*. Essa lacuna de pesquisa se intensifica ainda mais quando se considera a realização de experimentos para testar os efeitos da personalização. Em uma busca nas bases

¹ OTT - Over-The-Top diz respeito à distribuição de conteúdos pela internet sem que passe pelo controle de um serviço de telecomunicações, radiodifusão, TV a cabo/satélite ou IPTV.

Capes, Scielo, Spell, Redalyc e Google Acadêmico², em 2019, sem corte temporal, não foi encontrado nenhum artigo que falasse sobre algoritmos personalizados para plataformas de vídeo *online*, apenas consegue-se encontrar artigos que se refiram a algoritmos personalizados, mas quase sempre com o intuito de publicidade (MEJÍA et al., 2010; HALLINAN; STRIPHAS, 2014; CHEN-YI LIN; HAN-SHEN CHEN, 2019). Nenhum artigo foi encontrado investigando a eficácia dos algoritmos de personalização para a área de entretenimento e vídeos online, muito menos com pesquisas experimentais.

Desta forma surge o problema de pesquisa que este estudo busca responder: A utilização de algoritmos personalizados em plataformas de vídeo online influencia na experiência do usuário, consequentemente aumentando a intenção de compra?

1.2 OBJETIVOS

1.2.1 Objetivo geral

Caracterizar a influência dos algoritmos de personalização de conteúdo em plataformas online de entretenimento em vídeo.

1.2.2 Objetivos específicos

- a) Caracterizar o papel da inteligência artificial e *Big Data* na cultura de consumo da sociedade;
- b) Compreender as influências negativas e positivas da personalização nas jornadas de compra;
- c) Testar a efetividade de um algoritmo de personalização em uma plataforma de conteúdo digital em vídeo.

² Pesquisa realizada com as seguintes palavras-chave: algoritmo personalizado; personalização; algoritmo Netflix; algoritmo Netlfix; algoritmo Youtube.

1.3 ESTRUTURA DO TRABALHO

Para o alcance dos objetivos específicos propostos o estudo foi dividido em três capítulos, o primeiro deles chamado “As mudanças nos hábitos de consumo da população” trata sobre modelos de comportamento e consumo de compra, as influências da Inteligência Artificial e da Big Data sobre a forma de se vender e comprar produtos e serviços e por fim o capítulo discute a repercussão positiva e negativa de técnicas de personalização tanto na produção quanto na disseminação dos produtos.

O segundo capítulo do desenvolvimento trata sobre os procedimentos realizados para executar o experimento, passando pelo delineamento da pesquisa, descrevendo quais serão as variáveis testadas no experimento, mostrando o perfil da amostragem e detalhando os processos de coleta e análise da amostra.

O terceiro capítulo do desenvolvimento retrata os resultados do experimento por meio de análises descritivas e inferenciais da amostragem. Por fim, obteve-se a conclusão da amostragem colhida do experimento e a interpretação desses dados a partir da revisão teórica realizada.

2 AS MUDANÇAS NOS HÁBITOS DE CONSUMO DA POPULAÇÃO

O embasamento teórico a seguir irá discorrer sobre a teoria do comportamento do comprador organizacional e *Behavioral Perspective Model* (BPM), explicando as principais características que influenciam o comportamento de compra. Após isso haverá a contextualização das mudanças no hábito de compra advindos do desenvolvimento da Inteligência Artificial e de técnicas de *Big Data* e por fim será apresentado os efeitos de ferramentas de personalização em plataformas digitais variadas.

2.1 COMPORTAMENTO DO CONSUMIDOR E O BEHAVIORAL PERSPECTIVE MODEL (BPM)

O comportamento do consumidor é um grande tema de pesquisa da área de Marketing e Administração, devido a esse fato, autores renomados na área possuem teorias e modelos para tentar explicar quais fatores influenciam na decisão de compra. Estas pesquisas quando demonstradas com experimentos agregam um valor ainda maior para as marcas, pelo fato de testarem na prática a aceitação da tecnologia por parte do consumidor.

O comportamento do consumidor pode ser estudado de diferentes pontos de vista tais como antropologia, história, economia, psicologia, sociologia, etc. (SOLOMON, 2002). As pesquisas sobre comportamento do consumidor começaram na década de 60 no campo da Psicologia. Primeiro a Psicologia Social utilizou dos conceitos de atitude, comunicação e persuasão para explicar o ato de consumir, depois a Psicologia Cognitiva acrescentou ao debate incorporando variáveis como memória, processamento de informação e tomada de decisão (JACOBY; JOHAR; MORRIN, 1998).

Apesar de muito aceita no mundo da ciência, a linha de pensamento da Psicologia Cognitiva foca na interação marca consumidor como uma experiência interna do mesmo. A posição cognitivista coloca o comportamento como começando dentro do organismo, adotando a posição de que o ser pensa e depois age. Esta teoria propõe que todas as ações possuem uma

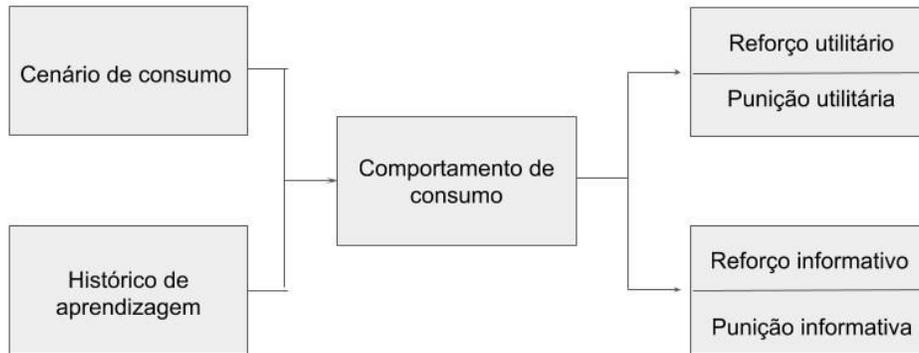
intenção, e que as pessoas decidem agir antes do ato. A escolha do consumidor é retratada pela Psicologia Cognitiva como uma sequência de envolvimento do ego que leva a uma mudança cognitiva, afetiva e conotativa que precede e pré-determina a compra ou a não compra do produto (SKINNER, 1953).

Entretanto, outros cientistas trouxeram uma nova maneira de explicar o fenômeno de consumo, esta nova linha de pensamento é denominada *Behaviorismo*, movimento que se tornou mais apropriado diante de uma visão predominantemente positivista e operacionalista da ciência, contribuindo com explicações não mentalistas sobre o comportamento humano como discorre Skinner (SIMON, 1980; SKINNER, 1985):

A Análise Experimental do Comportamento, diferentemente da Psicologia Cognitiva, faz uso de técnicas empíricas/ experimentais como o condicionamento operante, no qual a taxa de emissão da resposta é controlada por estímulos antecedentes e conseqüentes. Assim, a Psicologia Comportamental se refere à conseqüências ambientais, negando uma causa mental ou neural atribuídas a eventos intrapessoais e se tornando uma importante alternativa aos estudos sobre o comportamento do consumidor (SKINNER, 1953 pg 202).

Com o intuito de expandir os conhecimentos dentro do *Behaviorismo* foi criado o Modelo de Perspectiva Comportamental (em inglês *Behavioral Perspective Model*), modelo que busca explicar o comportamento do consumidor em função do histórico de aprendizagem do indivíduo combinado à um determinado cenário de consumo (FOXALL et al., 2011).

Figura 1 - Behavioral Perspective Model (BPM)



Fonte: adaptado de Foxall et al. (2006).

O cenário de consumo é a esfera social e física à qual as pessoas são expostas. O escopo do cenário pode se apresentar como relativamente aberto ou fechado de acordo com os elementos que o compõem, permitindo atuar sobre o comportamento do consumidor. O ambiente de consumo mais fechado tende a limitar o comportamento mediante sinalizações das ações que podem ser realizadas. Já ambientes mais abertos permitem aos indivíduos maior liberdade sobre as possibilidades de comportamentos (FOXALL et al., 2006).

O histórico de aprendizagem diz respeito a todas as experiências prévias similares ou relacionadas que o consumidor possui, ou seja, o comportamento do consumidor será moldado de acordo com experiências com o intuito de prever, evitando ou agindo, em relação a determinada compra (FOXALL, 1992, 2006).

O comportamento do consumidor, como descrito na Figura 1, é o resultado do cenário de consumo associado com o histórico de aprendizagem do indivíduo e, por isso, se configuram como elementos antecedentes ao consumo, uma vez que essas duas variáveis atuam sobre os indivíduos para quase todas as decisões que se toma no dia a dia. Portanto, é possível a partir da

pesquisa sobre comportamentos passados, predizer o comportamento do consumidor (PORTO; OLIVEIRA-CASTRO, 2015). Por outro lado, as consequências do comportamento são: reforços e punições informativas e utilitárias.

O reforço utilitário diz respeito aos benefícios diretos da posse e aplicação do produto ou serviço, um benefício funcional ou valor de uso. Já o reforço informativo, resulta do nível de status social, prestígio e aceitação obtido ao adquirir certo produto ou serviço. Além desses reforços, o comportamento de compra também envolve consequências aversivas, as quais também se subdividem em utilitárias e informativas (POHL; OLIVEIRA-CASTRO, 2008).

O campo do comportamento sobre o consumidor já possui grande amostragem de documentação científica. Porém, uma nova variável está sendo apresentada na equação quando se trata de compras. Com os avanços da tecnologia e com a ascensão da Inteligência Artificial (IA) novas ferramentas de persuasão estão sendo inseridas no cenário de consumo e no histórico de aprendizagem das pessoas, e por ser um assunto relativamente novo, ainda há muito para se entender sobre a interação do consumidor com a Inteligência Artificial. Este fato é acarretado devido aos avanço na tecnologia, que aumentaram a produção de artigos de consumo, fazendo com que o conceito de variedade esteja rapidamente substituindo o de marca como valor principal para o consumidor (ROYER; SANTOS, 2010).

Com o maior poder de escolha, devido a grande variedade de mercado, a competição aumentou. Um exemplo foi a quebra das locadoras de filmes, devido ao aumento de competitividade de plataformas de *streaming* de vídeo. Uma consequência da maior competitividade é o rompimento da lealdade dos consumidores com a marca, pois agora o cliente consegue achar no mercado opções com mais qualidade e menor preço do que anteriormente. Tem-se, então, um mercado com menos fronteiras, mais globalizado, exigindo assim, uma postura mais competitiva das empresas (ROYER; SANTOS, 2010).

2.2 IMPLEMENTAÇÃO DA INTELIGÊNCIA ARTIFICIAL E BIG DATA NA DECISÃO DE COMPRA

O termo Inteligência Artificial foi criado em 1956 pelo cientista da computação John McCarthy e é entendido como um cérebro fora do corpo humano capaz de aprender mais rápido do que os seres, além de ser capaz de se reprogramar para fazer melhorias em seu sistema (STERNE, 2017), apesar da criação do termo ter se dado apenas nesta época, é importante ressaltar que há manuscritos desde 1941 relatando sobre experiências *machine intelligence* e o escritor desses manuscritos foi Alan Turing.

A Inteligência Artificial está causando disrupção em diversos segmentos de mercado, um exemplo muito claro desta mudança é a Iron Ox, uma fazenda hidropônica totalmente controlada por robôs. Com a ajuda de IA um robô consegue analisar quanto de água uma planta precisa e o tempo perfeito para colher o alimento, e este não é o único empreendimento que utiliza dessa aplicação. O conceito de Inteligência Artificial irá se estender ainda a muitas empresas e produtos. Destaca-se que o ponto de quebra que esta tecnologia traz é a assertividade, a precisão e a capacidade de se adaptar (Pequenas Empresas & Grandes Negócios, 2019).

Um dos principais elementos para se entender IA é o *Machine Learning*. Esse termo foi criado em 1959 pelo engenheiro do Massachusetts Institute of Technology (MIT) Arthur Samuel. Arthur (1959) foi um grande pioneiro da Inteligência Artificial e ele descreve *Machine Learning* como “um campo de estudo que dá aos computadores a habilidade de aprender sem terem sido programados para tal”, ou seja, estas máquinas são capazes de realizar a autoaprendizagem.

Essa tecnologia começou cada vez mais a ser usada para detectar padrões de todos os tipos, como os de consumo, padrões de imagens de satélite, de aprendizagem e entre outros, até que este conceito foi se aprimorando, as máquinas foram processando mais informações, a quantidade de dados utilizados para detectar uma variável se tornou imensurável, por isso foi necessário o aprimoramento dos algoritmos, resultando em redes neurais com mais camadas intermediárias, dando origem ao termo *Deep Learning*.

A Inteligência Artificial teve um grande ponto de quebra em 2016, não só com os desdobramentos do *Deep Learning*, mas principalmente relacionado a forma com que as pessoas começaram a absorver essa tecnologia. Grandes especialistas de marketing já sentem que seus públicos estão prontos para consumir tal inovação (ADTHEORENT, 2018), porém ela já está

sendo utilizada por grandes empresas há muito tempo, como Google, Amazon, entre outras. Entretanto, a consciência deste fato parece só ter se dado recentemente.

Alguns acontecimentos históricos contribuíram para a disseminação desta informação de como os dados dos indivíduos estavam sendo usados pelas empresas. Um grande marco foi a campanha política do então presidente dos Estados Unidos (EUA) Donald Trump, empresário renomado que já entendia o poder dos dados e assim o utilizou em sua campanha, influenciando grande parte dos eleitores estadunidenses por meio da *Cambridge Analytica*, estratégia que combinava *big data*, psicométrica, target marketing atuando sob nichos de eleitores a partir de um grande banco de dados advindo das redes sociais dos usuários.

Outro marco importante foi a criação da Lei nº 13.709/2018, com edição pelo teor da Lei nº 13.853/2019, denominada Lei Geral de Proteção de Dados Pessoais (LGPD), ao qual entrará em vigor em agosto de 2020. Essa Lei dispõe sobre o tratamento de dados pessoais, inclusive nos meios digitais, por pessoa natural ou por pessoa jurídica de direito público ou privado, com o objetivo de proteger os direitos fundamentais de liberdade e de privacidade e o livre desenvolvimento da personalidade da pessoa natural. Convém destacar o art. 2º da Lei em comento, *in verbis*:

Art. 2º A disciplina da proteção de dados pessoais tem como fundamentos:
I - o respeito à privacidade;
II - a autodeterminação informativa;
III - a liberdade de expressão, de informação, de comunicação e de opinião;
IV - a inviolabilidade da intimidade, da honra e da imagem;
V - o desenvolvimento econômico e tecnológico e a inovação;
VI - a livre iniciativa, a livre concorrência e a defesa do consumidor; e
VII - os direitos humanos, o livre desenvolvimento da personalidade, a dignidade e o exercício da cidadania pelas pessoas naturais (BRASIL, 2019).

Hoje existe mais conhecimento sobre a utilização dos dados públicos e privados no mundo do que a dez anos atrás, porém ainda é muito nebulosa a maneira como é feita a troca, entre empresas, de informações sobre as pessoas sem o consentimento do usuário. E este ainda será um problema da próxima geração, pois mesmo com a criação de uma lei regendo o uso desses

dados, ainda há muitas etapas nesse processo para que a sociedade se sinta resguardada, pois está vivendo-se a era na qual as empresas disputam uma corrida mercadológica pelo poder de controle dos dados da população.

Dados são o novo petróleo. Essa afirmação foi feita por Clive Humby, matemático londrino, e já é utilizada por muitos empresários que começaram a investir seu dinheiro nesta ferramenta de marketing, chamada *Big Data*.

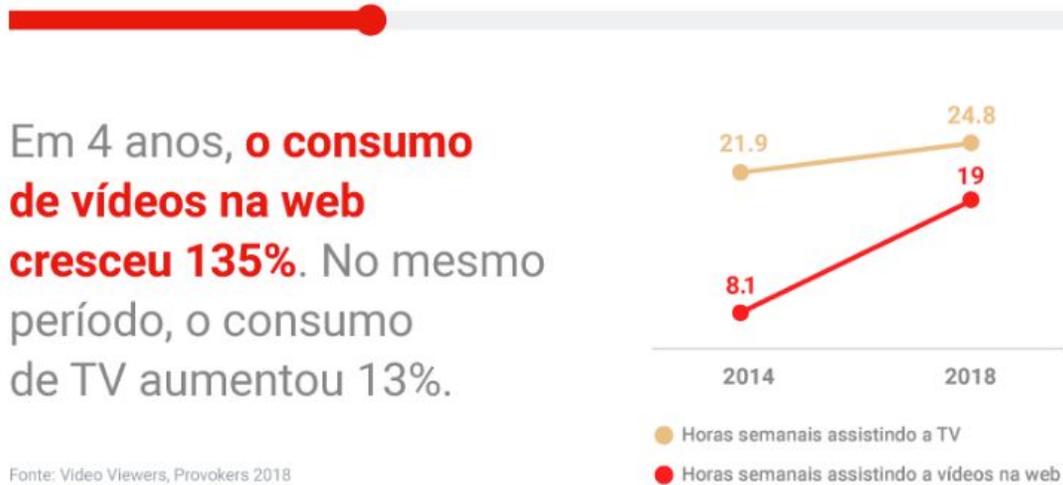
A definição de *Big Data* está relacionada aos desafios de crescimento de dados e oportunidades, como sendo tridimensional, ou seja, o aumento do volume (quantidade de dados), velocidade e as variedades (gama ou tipos de dados) e as fontes de dados (LANEY, 2001).

Com o crescimento da Inteligência Artificial e *Big Data* o mercado foi respondendo aos estímulos de implementar tecnologia em seus produtos e cada vez mais se apropriando do termo *Machine Learning*, e este processo abarca tanto as etapas de desenvolvimento de seus produtos como a melhoria de veiculação dos mesmos. Um exemplo do aprimoramento dos produtos são as novas assistentes virtuais que utilizam de IA para se comunicar de forma inteligente e personalizada com seus usuários, e um exemplo de veiculação utilizando *Machine Learning* são os anúncios programados pelo Google Adwords que utilizam de parâmetros de comportamento para indicar melhores produtos para os consumidores.

Alguns autores da área de marketing sugerem que a maneira de se fazer marketing hoje em dia se transformou completamente desde que os dados começaram a serem cruzados e analisados a partir da *Big Data* (EREVELLES et al., 2016). Essa mudança se deve ao grande volume de informações que uma empresa consegue colher sobre seu público alvo, e isso é interessante para as marcas pois ao saber as preferências de um indivíduo torna-se mais fácil conhecer os pontos fracos de seu consumidor. Além disso, a marca começa a se inserir nos momentos em que a pessoa se encontra mais suscetível a comprar.

A combinação de Inteligência Artificial e *Big Data* para a estratégia de um produto é crucial dentro do plano de marketing de uma empresa, porém pouco se tem de estudos experimentais para compreender os efeitos desta combinação em plataformas de entretenimento em vídeo, mesmo sendo um segmento em ascensão, como mostra o estudo realizado pela Video Viewers (PROVOKERS, 2018).

Figura 2 - Gráfico sobre consumo de vídeos na web



Fonte: Video Viewers, Provokers 2018

A figura 2 apresenta um infográfico com os resultados de um estudo divulgado pela Google em 2018. A figura em questão apresenta o crescimento de 135% acerca do consumo de vídeos na web nos últimos quatro anos, e ainda compara com o crescimento televisivo, o qual foi de apenas 13% no mesmo período. Apesar do grande crescimento no setor não há muita produção científica analisando os algoritmos de personalização para entender o por que do sucesso dessas plataformas, pois o código fonte dos principais *players* do mercado ainda é velado para proteger seus dados da concorrência.

FIGURA 3 - Gráfico comparativo de consumo entre plataformas de vídeo online



Fonte: Vídeo Viewers, Provokers 2018

A Figura 3 demonstra a taxa de crescimento do Youtube, sendo essa a plataforma mais assistida em 2018 no Brasil, batendo cinco vezes o número de visualizações da televisão aberta e sete vezes o uso de redes sociais. Estes dados revelam uma tendência, uma vez que o segundo maior *player* do mercado é a Netflix, outra plataforma que também utiliza métodos de personalização para vender seu produto da melhor maneira, ainda que estes dois gigantes estejam buscando a cada dia melhorar seus algoritmos de personalização para tal.

Pesquisas mostrando como a personalização pode ser eficaz para aumentar o consumo estão começando a ser feitas no mercado e este estudo busca, de maneira experimental, tentar revelar uma tendência nesta área para trazer um argumento de implementação dessas metodologias para dentro das empresas.

2.3 EFEITOS DAS FERRAMENTAS DE PERSONALIZAÇÃO EM PLATAFORMAS ONLINE

A personalização online é um processo automatizado que identifica padrões e características de navegação, analisa as preferências de usuário similares e entrega o conteúdo adequado a ele (LAVIE et al., 2010). Uma pesquisa global realizada pela Evergage (MCCLAY,

2015) apontou que 91% das empresas no meio online usam ou pretendem usar estratégia de personalização.

Estratégias de personalização de conteúdo e promoção são amplamente utilizadas por várias empresas, pois esta técnica pode trazer benefícios tanto para as mesmas quanto para os usuários através da otimização do tempo, dando o produto ao consumidor de maneira mais rápida e prática. Além disso, a personalização torna o marketing do negócio mais individualizado e pessoal (VENSANEN, 2000), aproximando o usuário e favorecendo uma oportunidade de compra futura (KOMIAK; BENBASAT, 2006).

Segundo pesquisa da Evergage (MCCLAY, 2019), as empresas que utilizam personalização observaram estas mudanças em suas métricas: aumento da conversão (em 65%), aumento do engajamento do visitante (em 62%) melhora da experiência do usuário (em 61%), além de apontarem aumento na geração de novos clientes (FREITAG, 2016).

Corriqueiramente a estratégia de personalização se baseia em dois objetivos: primeiro deve-se controlar o conteúdo, como ele será apresentado e o momento ideal para maximizar o engajamento para se ter uma resposta favorável do consumidor. O segundo objetivo seria aumentar a identificação e aceitação com a marca para maximizar oportunidades futuras. (TAM; SHUK, 2006)

Além dos benefícios mais voltados para o público, o bônus desta prática para as empresas é bem relevante, pois estes dados coletados da personalização revelam *insights* sobre os produtos e a forma que a empresa pode vendê-los. Uma estratégia implementada pela Netflix, utilizando de algoritmos de personalização, foi a criação da série Stranger Things. Neste caso as preferências do público foram combinadas por meio do cruzamento de dados e assim a plataforma pôde lançar um material quase que irresistível para o *target* almejado.

Esse tipo de estratégia é muito válida, pois a indústria cinematográfica movimenta muito capital. Só em 2018 o segmento registrou lucro de 96,8 bilhões de dólares em todo o mundo, incluindo mais de 40 bilhões apenas em bilheterias, de acordo com números publicados pela Motion Picture Association of America (MPAA) (MUSILLI, 2019). Por isso é muito arriscado e custoso para as produtoras produzirem um conteúdo sem qualquer tipo de taxa de previsão de

aceitação do público. Ou seja, mais uma vez a personalização, *Big Data* e IA se mostram relevantes para este mercado.

Mesmo não sendo um conceito atual, se utiliza até hoje a ideia de que a personalização pode ser vista como uma forma de criação de crença no consumidor e de que o mesmo está recebendo atenção de maneira exclusiva (DILLMAN; FREY, 1974), e essa ideia é amável por parte dos telespectadores que se sentem próximos da marca. Além disso, o consumidor recebe apenas mensagens consideradas de seu interesse – o que pode aumentar a intenção de compra (PAVLOU; STEWART, 2000).

Apesar de todos os benefícios de se ter a personalização de conteúdo, existem situações em que a personalização traz impactos negativos na sociedade e também acarreta em más percepções do consumidor sobre a marca. Com a criação de *Big Data* as empresas começaram a investir milhões de dólares em *ads* em todas as plataformas digitais imagináveis, devido ao grande retorno financeiro por parte dessas, porém devido ao lucro gerado por meio das redes sociais, as empresas começaram a introduzir de maneira abusiva propagandas a estes meios de comunicação transformando as plataformas em grandes alvos de venda e compra online. Exemplo disso é o aumento no segmento de influenciadores digitais que se aproveitam dessa vontade das marcas de se propagarem na internet para fazer disso um sustento.

Essa prática de vendas contínuas nas plataformas começou a gerar consequências negativas em seus consumidores, sendo uma das três reclamações mais apontadas pelos usuários. As outras duas reclamações mais apontadas são: o mal funcionamento e a invasão de privacidade nestas plataformas (FREITAG, 2016).

O mal funcionamento da personalização online ocorre quando há entrega de um conteúdo irrelevante ou tendencioso ao usuário, o que leva a desconfiança da competência e integridade do agente por parte do usuário (CHAU et al., 2013). O mal funcionamento se caracteriza quando a personalização não condiz com o histórico de compra do consumidor, indicando a ele algo que não se adequa ao seu perfil de compra e nem ao que ele veio procurando na rede nos últimos tempos (FREITAG, 2016).

A invasão de privacidade é um dos fatores críticos de influência dos efeitos negativos da personalização online (LEE, et al., 2015). O sentimento de se sentir observado e rastreado pelas

empresas gera medo e repulsa do consumidor com a marca, e isso é causado principalmente pelo fato dos consumidores não compreenderem o tipo de informação que as empresas têm acesso (FREITAG, 2016).

As reclamações de repetição excessiva em sua maioria não são acerca de um conteúdo que o telespectador não queria ver, mas sim de um conteúdo que era relevante para aquele perfil, porém a marca criou um quantidade de momentos de exposição de maneira excessiva, cansando a vista do telespectador em relação ao produto (FREITAG, 2016).

Esses pontos negativos levantados tornam ainda mais relevante os estudos sobre os algoritmos de personalização, pois essas más percepções se deram, em sua maioria, a partir de um erro cometido pela marca, e para melhorar a relação das marcas com os instrumentos de personalização é necessário aumentar a gama de pesquisas na área.

Esses estudos sobre personalização se fazem relevantes pois é notório no mercado a crescente procura por essas ferramentas por parte das marcas, pois personalização, recomendações, seleção dinâmica de conteúdo e estilos de exibição dinâmicos (STERNE, 2017) serão habilidades necessárias a qualquer profissional da área de marketing.

Todas essas pesquisas realizadas e citadas acima focaram em analisar conteúdos promocionais enviados aos consumidores por meio de diferentes plataformas digitais e físicas. Porém pouco se tem na literatura demonstrando o efeito da personalização em canais de entretenimento em vídeo na web, objeto que este experimento em vigor busca testar.

3 MÉTODOS E TÉCNICAS DE PESQUISA DA FASE EXPERIMENTAL

Nesta seção será apresentado o delineamento da pesquisa, o instrumento e o objeto final para a realização de um experimento que visa entender como a personalização de plataformas de conteúdo influencia na decisão de compra dos consumidores.

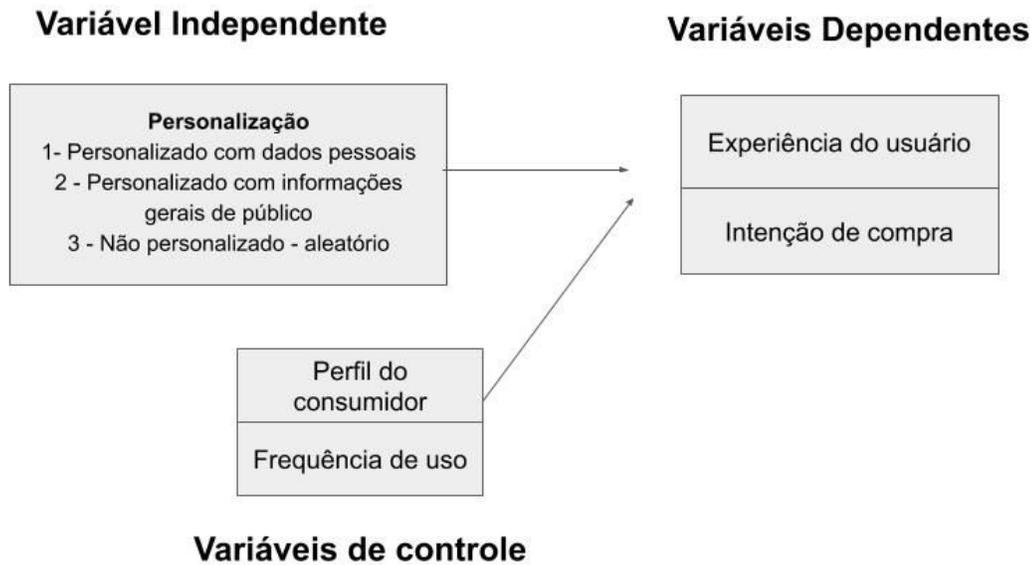
3.1 DELINEAMENTO DE PESQUISA

A presente pesquisa possui caráter quantitativo (FONSECA, 2002), em que informações são transformadas em dados numéricos de forma a possibilitar análises e classificações (FREITAS; PRODANOV; FREITAS, 2013). O delineamento é experimental, a fim de observar a ocorrência de relações ou não de causa e efeito entre as variáveis dependentes e independentes (COZBY, 2003). Com isso deseja-se avaliar a efetividade da personalização do conteúdo em plataformas características de conteúdo de entretenimento online. O recorte temporal adotado é o transversal, pois não há um estudo comparando diversos cenários de consumo no tempo, apenas uma amostragem retirada do experimento em um único espaço temporal.

3.2 VARIÁVEIS E MODELO DE PESQUISA

Para a realização do experimento foi necessário primeiro realizar a modelagem que dará base para os testes estatísticos. Portanto, o modelo de pesquisa se encontra na figura 4 abaixo:

Figura 4 - Modelo de pesquisa



Fonte: Elaboração própria (2019).

O objetivo principal deste estudo é investigar a influência dos algoritmos de personalização sobre a experiência do usuário e a intenção de compra no que diz respeito a conteúdos de entretenimento em vídeo por meio de plataformas online, a partir desse objetivo a modelagem foi idealizada. A variável independente (V.I) do estudo é a personalização, contendo três graus dentro desta V.I: o primeiro grau é a personalização nula; o segundo grau é a média personalização, que consiste em apenas organizar dentro da plataforma os filmes de acordo com o ranqueamento geral de bilheterias ao redor do mundo; e o terceiro grau é o mais personalizado possível, que utiliza das informações de gosto pessoal em relação a filmes para organizar a plataforma.

Neste estudo foi necessário testar duas variáveis dependentes (V.Ds): a primeira foi a experiência do usuário em relação a cada uma das três plataformas, que foi medida comparando

a média das notas dadas para as plataformas; e a segunda V.D foi a intenção de compra sinalizada por parte dos respondentes, medida por meio da pergunta referente a qual das três plataformas o telespectador assinaria.

As Variáveis de controle (V.C) foram: dados demográficos, como idade, gênero, renda e escolaridade; e a frequência de uso serão analisadas a partir dos dados de horas de uso semanais das plataformas Youtube e Netflix que os respondentes forneceram. Estas foram separadas em duas categorias, *light* e *heavy user*, sendo *light* menor que 5 horas semanais e *heavy* igual ou mais de 5 horas semanais.

3.3 PERFIL E AMOSTRA DOS PARTICIPANTES

A amostra total foi de 452 respondentes, porém apenas 421 respostas foram válidas para análise, pois 31 respostas eram duplicadas. O perfil de respondentes foi bem diverso, tendo pessoas desde 18 até 83 anos, de todas as classes sociais e de alguns gêneros.

A Tabela 1, a seguir, caracteriza a amostra de 421 respondentes do questionário realizado demonstrando suas características e as determinadas frequências de respostas.

TABELA 1 - Perfil da amostra

Variável	Item	N	%
Idade	18 e 19 anos	44	10.45
	20 anos	35	8.31
	21 anos	53	12.58
	22 anos	81	19.23
	23 anos	59	14.01
	24 anos	31	7.36
	25 anos	17	4.03
	26 a 29 anos	40	9.50

	30 a 40 anos	33	7.83
	Mais de 40 anos	28	6.65
	Total	421	100

Escolaridade	Analfabeto	0	0
	Ensino fundamental incompleto	0	0
	Ensino fundamental completo	0	0
	Ensino médio incompleto	2	0.47
	Ensino médio completo	18	4.27
	Superior incompleto	257	61.04
	Superior completo	75	17.81
	Pós-graduação incompleta ou completa	66	15.67
	Total	421	100

Gênero	Femino	236	56.05
	Masculino	178	42.28
	Outro	7	1.66
	Total	421	100

Renda	Classe A	179	42.51
	Classe B	77	18.28
	Classe C	124	29.45
	Classe D	29	6.88
	Classe E	12	2.85

	Total	421	100
<hr/>			
Anos de anos de uso Youtube	Não uso	6	1.42
	Menos de um ano	2	0.47
	Utilizo há um ano	0	0
	Utilizo há dois anos	4	0.95
	Utilizo há três anos	3	0,71
	Utilizo há quatro anos	7	1.66
	Utilizo há cinco anos	19	4.51
	Utilizo há mais de cinco anos	378	89.78
	Total	421	100

Frequência de compra Youtube	Light User	286	67.93
	Heavy User	135	32.06
	Total	421	100

Anos de anos de uso Netflix	Não uso	17	4.3
	Menos de um ano	7	1.7
	Utilizo há um ano	14	3.6
	Utilizo há dois anos	53	12.9
	Utilizo há três anos	98	23.6
	Utilizo há quatro anos	84	20.2
	Utilizo há cinco anos	53	12.9

	Utilizo há mais de cinco anos	87	21.0
	Total	421	100
<hr/>			
Frequência de compra Netflix	Light User	266	63.18
	Heavy User	155	36.81
	Total	421	100

Fonte: Elaboração própria (2019).

Como se pode averiguar na tabela 1, o público mais presente na amostragem foram jovens de 21 a 23 anos (45,8%) com nível superior incompleto (61%), sendo essas mulheres (56%) da classe A (42,5%). Em relação ao perfil de uso das plataformas Youtube e Netflix constata-se que a maioria utiliza Youtube há mais de cinco anos (89,7%) e Netflix a maioria utiliza há três anos (23,6%) ou há mais de cinco anos também (21%).

Foi feita a separação de consumidores em relação à quantidade de tempo em que os telespectadores passavam navegando nas duas plataformas, consideramos *light users* pessoas que utilizam menos de 5 horas por semana e *heavy users* pessoas que consomem cinco ou mais horas por semana. Em ambas as plataformas de *streaming*, observa-se que a maioria das pessoas são *light users* (Youtube: 67,9%; Netflix: 63,18%).

3. 4 PROCEDIMENTOS DE COLETA E ANÁLISE DE DADOS

O instrumento de pesquisa consistiu em um site com algoritmos personalizados, no qual o protótipo está disponível por meio deste link <<https://goofy-cray-ebc15e.netlify.com/#/>>. Primeiramente é importante ressaltar que todas as informações como foto, descrição do filme, ano de lançamento, nome, gênero do filme e vendas de bilheteria foram retiradas de uma *Application Programming Interface (API)*³ do TMDb.

³ API é um conjunto de rotinas e padrões de programação para acesso a um aplicativo de software ou plataforma baseado na Web

A lógica do site foi colher na primeira página os dados demográficos do respondente e também dados em relação a preferências cinematográficas, sendo esses: se a pessoa preferia filmes recente ou antigos, quais eram seus três gêneros de filme favoritos e os dois gêneros que menos gostava. Então o experimento corria para uma breve explicação de como funcionaria e o indivíduo era exposto a três plataformas de filmes. Entre a visualização de cada uma dessas plataformas ele dava notas as mesmas, e ao final ele avaliava novamente todas elas. A reavaliação das plataformas foi feita para que o respondente pudesse ter a chance de mudar sua nota após ter a visão dos três panoramas apresentados.

O experimento contou com três graus de personalização, que foram configurados em cada uma das três plataformas de filmes apresentadas no experimento. A primeira plataforma era completamente não personalizada, ou seja, o algoritmo tornava completamente randômica a escolha de filmes observada pelo telespectador. O nome desta plataforma era Filmex. A segunda plataforma era personalizada de acordo com o ranqueamento das bilheterias, ou seja, apareciam dentro do carrossel de filmes e em ordem decrescente, as películas que foram melhor aceitas e assistidas pelo público. A ordem em que os gêneros foram organizados foi aleatória, configurando a plataforma denominada de Filmix.

A terceira plataforma se chamava Filmux. Esta plataforma foi a completamente personalizada a partir dos dados fornecidos pelos respondentes na própria pesquisa. Logo no início da página já aparecia uma mescla dos gêneros favoritos. Esta seleção ficou em uma linha chamada “Recomendações para você”. As três linhas abaixo desta apresentavam os três gêneros favoritos do indivíduo, também em relação a sua ordem de escolha descrita na primeira parte do experimento. Além disso, os dois gêneros apontados pela pessoa como menos favoritos foram excluídos dessa aba.

A escolha de nomes diferentes, porém parecidos, nas três plataformas foi intencional, uma vez que não queríamos acrescentar mais uma variável determinante na escolha da compra, porém na prototipagem vimos que utilizar exatamente o mesmo nome deixava o respondente confuso em relação a qual plataforma ele estava navegando, dificultando a tarefa de dar nota para cada uma das três plataformas.

Ao final a pessoa respondia qual das três plataformas assinaria e esta opção foi considerada como a sinalização da intenção de compra, que é uma das variáveis dependentes que este estudo buscava testar. A outra variável dependente da modelagem era a experiência que o usuário teve com cada uma das plataformas. Esta variável foi medida ao colher a nota de cada uma das plataformas.

O site foi hospedado em um domínio comprado pela autora do estudo. Os dados foram colhidos e armazenados em um DataSet na plataforma *Airtable* e em relação ao processo de análise de dados foram utilizadas algumas plataformas para tratar e analisar tais informações, sendo elas SPSS⁴, R Studio⁵ e Excel⁶. Após a mineração dos dados foram realizados testes descritivos e associativos

⁴ SPSS é uma ferramenta de análise estatística desenvolvida pela IBM

⁵ R Studio é um aplicativo de análise estatística, para computador, que aceita a linguagem de programação R

⁶ Excel é uma ferramenta para armazenamento e análise de dados do pacote Office.

4 RESULTADOS E DISCUSSÃO DA FASE EXPERIMENTAL

Após a coleta de dados foram realizadas análises descritivas da amostragem e em sequência análises associativas do mesmo *Dataset*, portanto esse capítulo irá tratar desses resultados.

4.1 ANÁLISES DESCRITIVAS DAS PLATAFORMAS

TABELA 2 - Análise de distribuição de notas por plataforma

Variável	Nota	N	%
Plataforma 1	1	16	3,8
	2	43	10,2
	3	139	33
	4	143	34
	5	80	19
	Total	421	100
Plataforma 2	1	7	1,7
	2	32	7,6
	3	107	25,4
	4	170	40,4
	5	105	24,9
	Total	421	100
Plataforma 3	1	3	0,7
	2	23	5,5
	3	96	22,8
	4	163	38,7

	5	136	32,3
	Total	421	100

Fonte: Elaboração própria (2019).

TABELA 3 - Média das notas nas plataformas

Variável	Plataforma	Média de notas	Desvio padrão
Média das notas nas plataformas	1	3.54	1.02
	2	3.79	0.95
	3	3.96	0.91

Fonte: Elaboração própria (2019).

Como evidenciado na metodologia, havia duas formas de avaliação das plataformas, a primeira forma era dada a partir de notas que os respondentes atribuíram a cada uma das três plataformas, podendo essa nota variar de 1 a 5, esses dados estão evidenciados nas tabelas 2 e 3. A segunda maneira de avaliação era colhida ao final através da pergunta qual das três plataformas o respondente escolheria, esta informação se encontra compilada na tabela 4 abaixo.

A tabela 2 demonstra a análise descritiva de notas dadas as experiências do usuários nas três plataformas, já a tabela 3 expõe a média das notas em cada uma das plataformas e o desvio padrão da mesma.

Como pode ser observado na tabela 2 e 3 acima, a plataforma 1, que era a completamente não personalizada, teve suas notas concentradas majoritariamente entre 3 (33%) e 4 (34%). Na plataforma 2 observa-se que as pessoas deram, majoritariamente, nota 4 (40,4%), porém a nota 3 (25,4%) e 5 (24,9%) aparecem com igual distribuição em seguida.

A plataforma 3 gerou uma reação um pouco diferente em relação aos telespectadores, nas outras plataformas a nota 3 aparecia com bastante frequência, já na terceira a nota 3 não assume um papel de tanto destaque, uma vez que ela representa apenas 22,8% do total. Enquanto isso, a nota 4 (38,7%) e a nota 5 (32,3%) se destacam como as mais votadas pelos participantes. Como

pode-se notar, a nota 5, considerada a mais alta da escala utilizada, se destaca bem mais no cenário da terceira plataforma, mesmo que a média das três plataformas tenham sido parecidas (todas ficaram na casa 3). Sendo assim, pode-se inferir que a experiência do usuário na plataforma 3 foi a melhor avaliada pelos usuários no experimento.

TABELA 4 - Análise de distribuição de votos por plataforma

Variável	Plataforma	N	%
Voto por plataforma	1	86	20,4
	2	127	30,2
	3	208	49,4
Total		421	100

Fonte: Elaboração própria (2019)

Na tabela 4 observa-se a distribuição de votos colhidos na pergunta final, que era “Supondo que você possui dinheiro para assinar qualquer uma dessas plataformas e que elas custassem exatamente o mesmo preço, qual delas você assinaria?”. Retira-se do resultado que 86 pessoas (20,4%) assinariam a plataforma 1, 127 (30,2%) assinariam a plataforma 2 e 208 (49,4%) assinariam a plataforma 3.

TABELA 5 - Análise descritiva de escolaridade em relação a preferência de compra

Grau de escolaridade	Preferência de compra							
	1		2		3		Total	
Ensino médio incompleto	1	0,24%	0	0%	1	0,24%	2	0,48%
Ensino médio completo	0	0%	9	2,25%	9	2,25%	18	4,5%

Ensino superior incompleto	59	14,01%	74	17,58%	125	29,69%	258	61%
Ensino superior completo	13	3,09%	28	6,65%	35	8,31%	76	18,05%
Pós graduação	13	3,09%	16	3,80%	38	9,03%	67	15,91%
Total	86	20,43%	127	30,17%	208	49,41%	421	100%

Fonte: Elaboração própria (2019).

Na tabela 5 pode ser observado a quantidade de pessoas que votaram em cada uma das três plataformas em relação a sua escolaridade. Dessa tabela é possível concluir que em todos os graus de escolaridade a plataforma 3 se destacou, seguindo a mesma lógica geral de votos da amostragem total, sendo essa: plataforma 3<2<1.

TABELA 6 - Análise descritiva de gênero em relação a preferência de compra

Sexo	Preferência de compra							
	1		2		3		Total	
Feminino	44	10,45%	70	16,63%	122	28,98%	236	56,06%
Gênero fluido	0	0%	1	0,2%	0	0%	1	0,24%
Masculino	40	9,50%	54	12,83%	84	19,95%	178	42,28%
Não binário	0	0%	2	0,48%	2	0,48%	4	0,95%
Prefiro não dizer	2	0,48%	0	0%	0	0%	2	0,48%
Total	86	20,43%	127	30,17%	208	49,41%	421	100%

Fonte: Elaboração própria (2019).

No geral todos os gêneros preferiram a plataforma três, porém quando comparados os gêneros masculino e feminino observa-se um quantidade relativa maior de mulheres (28,98%) votando na plataforma 3 do que de homens (19,95%). A plataforma 1 e 2 possuem distribuição parecida de votos entre os gêneros masculino e feminino. Portanto, é possível identificar uma ligeira diferença entre o comportamento dos dois gêneros, porém esta diferença se mostra insignificante para a amostragem em questão. Não foi possível analisar os outros gêneros existentes devido ao baixo número de respondentes.

TABELA 7 - Análise descritiva de renda em relação a preferência de compra

Renda	Preferência de compra							
	1		2		3		Total	
Classe A	44	10,45%	51	12,11%	84	19,95%	179	42,52%
Classe B	15	3,56%	23	5,46%	39	9,26%	77	18,29%
Classe C	18	4,28%	39	9,26%	67	15,91%	124	29,45%
Classe D	7	1,66%	9	2,14%	13	3,09%	29	6,89%
Classe E	2	0,47%	5	1,19%	5	1,19%	12	2,85%
Total	86	20,42%	127	30,16%	208	49,39%	421	100%

A Tabela 7 descreve a quantidade de pessoas de cada classe que votaram em cada uma das plataformas. As classes com maior número de respondentes foram as classes A (42,52%) e C (29,45%). Todas as classes reproduziram um comportamento semelhante aos resultados gerais, ou seja, a plataforma mais votada percentualmente em cada uma das classes também foi a terceira, além disso a distribuição de votos segue a proporção 2:3:5.

TABELA 8 - Análise descritiva do tempo dedicado ao Youtube em relação a preferência de compra

Tempo no Youtube	Preferência de compra							
	1		2		3		Total	
Menos de 1 hora	22	5,23%	21	4,99%	40	9,5%	83	19,71%
1 hora	11	2,61%	14	3,33%	25	5,94%	50	11,88%
2 horas	14	3,33%	23	5,46%	29	6,89%	66	15,7%
3 horas	11	2,61%	14	3,33%	19	4,51%	44	10,45%
4 horas	8	1,90%	14	3,33%	21	4,99%	43	10,21%
5 horas	4	0,95%	11	2,61%	15	3,56%	30	7,13%
Entre 5 e 10 horas	10	2,38%	17	4,04%	39	9,26%	66	15,7%
Mais de 10 horas	6	1,43%	13	3,09%	20	4,75%	39	9,26%
Total	86	20,43%	127	30,17%	208	49,41%	421	100%

Fonte: Elaboração própria (2019).

São considerados *heavy users* usuários que utilizam Youtube 5 horas ou mais no total semanal, e esse grupo representa um total de 135 pessoas (32,06%). E considerando *light users* os usuários que utilizam menos de 5 horas semanais a plataforma, a somatória de pessoas resulta em 286 (67,93%) usuários. A opção mais escolhida em relação a tempo declarado de audiência no Youtube é o período de “Menos de uma hora” (19,71%), ou seja, pode-se declarar que a maior parte da amostragem não eram de usuários assíduos do Youtube.

TABELA 9 - Análise descritiva do tempo dedicado a Netflix em relação a preferência de compra

Tempo no Netflix	Preferência de compra							
	1		2		3		Total	
Menos de 1 hora	13	3,09%	23	5,46%	32	7,60%	68	16,15%
1 hora	8	1,9%	8	1,9%	18	4,28%	34	8,08%

2 horas	12	2,85%	16	3,8%	24	5,7%	52	12,35%
3 horas	11	2,61%	21	4,99%	30	7,13%	62	14,73%
4 horas	9	2,14%	15	3,56%	26	6,18%	50	11,88%
5 horas	10	2,38%	14	3,33%	27	6,41%	51	12,11%
Entre 5 e 10 horas	14	3,33%	22	5,23%	35	8,31%	71	16,86%
Mais de 10 horas	9	2,14%	8	1,9%	16	3,8%	33	7,84%
Total	86	20,43%	127	30,17%	208	49,41%	421	100%

Fonte: Elaboração própria (2019).

Se considerado *heavy user* o usuários que utilize Youtube 5 horas ou mais no total semanal, teremos um total de 155 pessoas (36,81%) nesta categoria. E considerando *light user* o usuários que utilize menos de 5h semanais a plataforma, a somatória de pessoas resulta em 266 (63,18%) usuários. A opção mais escolhida em relação a tempo declarado de audiência no Youtube é o período de “Entre 5 e 10 horas” (16,86%).

4.2 ANÁLISES DE ASSOCIAÇÃO DOS RESULTADOS EM RELAÇÃO A INTENÇÃO DE COMPRA

Após feita as análises descritivas, alguns dados foram cruzados a fim de responder se há interação entre as variáveis dependentes, variáveis de controle e variáveis independentes. O resultado se encontra a seguir nas tabelas 10, 11, 12, 13 e 14.

- Teste chi quadrado para independência

TABELA 10 - Teste chi quadrado para independência com a VD intenção de compra

Associações de qual assinatura com	Teste de independência		
	X-squared	Df	p-value
Escolaridade	11,817	8	0,1596
Gênero	12,625	8	0,1254

Renda	5,7675	8	0,6733
Horas no Youtube	8,5894	14	0,8564
Horas no Netflix	3,6505	14	0,9972

Fonte: Elaboração própria (2019).

H0: As variáveis são independentes, ou seja, não existe associação

H1: As variáveis não são independentes, ou seja, existe associação

O primeiro teste realizado foi o chi quadrado para independência, este teste busca entender se há relação entre duas variáveis, as variáveis combinadas na tabela 10 foram as variáveis de controle e a variável dependente, intenção de compra. Ou seja, o resultado que esse teste busca responder é, por exemplo, se a pessoa ver mais ou menos horas de Netflix ou Youtube gerou um comportamento padronizado, e assim se repetirá até testar a relação com todas as variáveis moderadoras que se encontram na primeira coluna da tabela 10.

Calculado o p-valor, que é a probabilidade de se rejeitar a hipótese nula quando a hipótese nula é verdadeira. Primeiro, é fundamental explicar que todo teste que busca testar uma hipótese precisa de uma hipótese nula e as hipóteses que se deseja comprovar, portanto a hipótese nula é aquela que é justamente a negação da hipótese que se está querendo testar. Sendo assim, o p-valor é o nível de significância que sua hipótese tem em relação a hipótese nula, ou seja, quanto maior o p-valor maior são os indícios para se poder negar a H0, que é a hipótese nula. Assim foi realizado o teste chi quadrado, assumindo um nível de significância de 5% e analisando os p-valores observados temos que para p-valores maiores do que 0,05, não há evidências estatísticas para rejeitarmos H0.

Avaliando os resultados apresentados na tabela 10, é possível observar que, para nenhum dos testes realizados, o p-valor foi menor do que 0,05. Dessa forma, não há evidências estatísticas para rejeitarmos que as variáveis são independentes, ou seja, não há associação entre as variáveis apresentadas e a intenção de compra sinalizada por nenhuma das plataformas.

Logo, pode-se afirmar que as variáveis de controle do modelo proposto não possuem influência na intenção de compra. Ou seja, tanto características demográficas, quanto

características de uso das plataformas (*heavy ou light users*) não possuem associação com a variável dependente intenção de compra.

- **Teste Shapiro-Wilk (teste de normalidade)**

TABELA 11 - Teste Shapiro-Wilk

Notas	Teste de normalidade	
	W	p-value
Nota 1	0,8953	<0,001
Nota 2	0,8734	<0.001
Nota 3	0,8534	<0,001

Fonte: Elaboração própria (2019).

H0: A amostra segue uma distribuição normal

H1: A amostra não segue uma distribuição normal

Em sequência foi feito o teste de Shapiro Wilk, que busca compreender se a amostragem segue uma distribuição normal, para a variável experiência do usuário. A distribuição normal é extremamente comum na natureza, sendo um exemplo prático a distribuição de altura na população, no qual a grande parte das pessoas se concentra numa altura mediana, sendo assim a distribuição normal prevê que a maior concentração de respostas na amostragem estará no nível intermediário, ou seja, essa pesquisa teria uma distribuição normal se a nota mais dada as plataforma fosse a nota 3, que na escala era o número intermediário.

Analisando os resultados da tabela 11 é possível notar que a variável “Nota” não segue uma distribuição normal, pois o p-valor está abaixo de 0,05. Essa informação inviabiliza a análise de variâncias, pois só é possível testar a variância de uma amostragem com distribuição normal.

- **Teste de Friedman (Comparação múltipla de médias)**

TABELA 12 - Teste de Friedman

	Teste de Friedman	
Notas	Chi - quadrado	p-value
Notas	59,269	<0,001

Fonte: Elaboração própria (2019).

H0: A média das notas para as 3 plataformas são iguais

H1: A média das notas para pelo menos 1 plataforma é diferente

O teste de Friedman é um teste estatístico não paramétrico, esse teste pode ser utilizado no caso dessa amostragem por ela não possuir distribuição normal, como verificado anteriormente. O mesmo é utilizado para analisar dados amostrais vinculados, ou seja, quando o mesmo indivíduo é avaliado mais de uma vez, o indivíduo aqui nesse caso são as plataformas e esse teste buscou entender se houve diferença das notas dadas para cada uma das três plataformas, por isso a H0, hipótese nula, foi “a média das notas para as 3 plataformas são iguais”, pois se quer concluir exatamente que elas são diferentes. O teste de Friedman não tem o objetivo de comparar puramente as médias, mas sim analisar de par em par a diferença das plataformas, pois apenas dessa forma pode-se inferir que uma obteve melhor desempenho que a outra.

Analisando a tabela 12 nota-se que existem evidências estatísticas para recusarmos a hipótese nula, uma vez que o p-valor é menor do que o nível de significância alfa de 5%. Em outras palavras, há evidências estatísticas para recusarmos que a média das notas para as 3 plataformas são iguais.

Desta forma pode-se passar para um teste de comparação de médias para afirmar qual das três plataformas possui uma média maior.

- **Teste de Wilcoxon pareado (Comparação de médias dois a dois)**

TABELA 13 - Teste de Wilcoxon pareado - Comparação de médias

	Notas		
Notas	Nota 1	Nota 2	Nota 3
Nota 1	1	<0,001	<0,001
Nota 2	<0,001	1	0,009
Nota 3	<0,001	0,009	1

Fonte: Elaboração própria (2019).

H0: Média 1 = Média 2 = Média 3

H1: Média 1 < Média 2

H2: Média 2 < Média 3

O teste de Wilcoxon pareado é utilizado para comparar se as medidas de posição de duas amostras são iguais no caso em que as amostras são dependentes. Sendo assim este teste busca evidenciar qual das três plataformas obteve um melhor desempenho quando comparada diretamente com outra.

- Plataformas 1 e 2

H0: Média 1 = Média 2

H1: Média 1 < Média 2

Comparando as plataformas 1 e 2 pode-se inferir que há evidências estatísticas para rejeitamos a hipótese nula de que as médias são iguais. Assim ficamos com a hipótese alternativa de que a média da nota para a experiência do usuário na plataforma 2 foi maior do que a na plataforma 1.

- Plataformas 2 e 3

H0: Média 1 = Média 2

H1: Média 1 < Média 2

Considerando um nível de significância de 10% e analisando os p-valores da tabela 13, há evidências estatísticas para rejeitarmos a hipótese nula de que as médias são iguais. Assim assume-se a hipótese alternativa de que a média da nota dada a experiência do usuário para a plataforma 3 foi maior do que a da plataforma 2.

Como foi rejeitada a hipótese nula e aceita a hipótese alternativa de que a média da nota para a experiência do usuário na plataforma 2 foi maior do que a da plataforma 1 e ainda que a média da plataforma 3 foi maior do que a da 2, podemos concluir que as médias das notas dadas a plataforma 3 são maiores do que as das plataformas 2 e 1.

Comparar apenas as médias das plataformas seria o suficiente para dizer que na amostragem desse experimento a plataforma 3 obteve melhor desempenho, porém o objetivo do estudo era comprovar que replicando esse experimento em outros cenários, os resultados seguiram o mesmo padrão, sendo assim foi feito o teste de Wilcoxon pareado, no qual tornou possível afirmar que a média da plataforma 3 não é maior apenas neste estudo apresentado, evidenciando que esse comportamento se desdobraria também a outras amostragens.

- Teste de Wilcoxon pareado (Comparação de médias dois a dois)

TABELA 14 - Teste de Wilcoxon pareado - Percepção da experiência usuário antes e depois

Notas antes	Notas depois		
	Nota 1	Nota 2	Nota 3
Nota 1	0,032	-	-
Nota 2	-	0,144	-

Nota 3	-	-	0,545
--------	---	---	-------

Fonte: Elaboração própria (2019).

H0: Nota i antes = Nota i depois

H1: Nota i antes diferente da nota i depois

Obs: i = plataformas de 1 a 3

Testada as médias das notas nas plataformas, agora testou-se a mudança de notas dadas antes e depois do usuário ter tido contato com as três plataformas, pois ao final ele pôde reavaliar todas as três plataformas novamente. Sendo assim, o teste de Wilcoxon pareado tem como intuito testar e comparar as médias das notas dadas as plataformas nesses dois momentos.

Considerando um nível de confiança de 5% e analisando os p-valores acima, há evidências estatísticas para rejeitarmos a hipótese nula de que as médias são iguais. Assim ficamos com a hipótese alternativa de que há diferença entre as notas das plataformas antes e depois. Sendo assim, pode-se confirmar que ter acesso ao panorama geral das três plataformas gerou diferença significativa na percepção do usuário. Percebe-se que ver todas as plataformas antes para depois dar seu voto gerou uma melhor percepção em todas as plataformas, pois todas receberam um aumento. Na plataforma 1 média da nota antes foi

4.3 ANÁLISE DE RELAÇÃO ENTRE A NOTA DA EXPERIÊNCIA DO USUÁRIO E INTENÇÃO DE COMPRA

A seguir encontra-se nas tabelas 15, 16, 17 e 18 as análises de relação entre as notas dadas as experiências do usuário e como isso afetou na intenção de compra.

- **Teste de Friedman (Comparação múltipla de médias)**

Para o estudo em questão dividiu-se o banco de dados em 3 grupos, os que escolheram a plataforma 1, 2 e 3 em grupos distintos. O objetivo era avaliar se a nota dada a plataforma

influenciava na escolha da intenção de compra. Ou seja, o intuito era descobrir em qual plataforma o indivíduo indicaria assinar caso ele desse notas iguais as plataformas.

TABELA 15 Teste de Friedman - Comparação de médias das plataformas

Decisão de compra	Teste de Friedman	
	Chi - quadrado	p-value
Plataforma 1	166,75	<0,001
Plataforma 2	254,7	<0,001
Plataforma 3	376,01	<0,001

Fonte: Elaboração própria (2019).

H0: A média das 3 notas é igual independente de qual plataforma for escolhida

H1: Pelo menos a média da nota de uma plataforma é diferente dependendo da plataforma escolhida

O teste de Friedman é um teste estatístico não paramétrico, ou seja, ele cabe no caso dessa amostragem por ela não possuir distribuição normal, como verificado anteriormente. Esse teste é utilizado para analisar dados amostrais vinculados, ou seja, quando o mesmo indivíduo é avaliado mais de uma vez, o indivíduo aqui nesse caso são as plataformas e esse teste buscou entender se houve diferença das notas dadas para cada uma das três plataformas, por isso a H0, hipótese nula, foi “ A média das três notas é igual independente de qual plataforma for escolhida”, pois se quer concluir exatamente que elas são diferentes independente da plataforma escolhida. O teste de Friedman não tem o objetivo de comparar puramente as médias, mas sim analisar de par em par a diferença das plataformas, pois apenas dessa forma pode-se inferir que uma obteve melhor desempenho que a outra.

Analisando a tabela 15 nota-se que existem evidências estatísticas para recusarmos a hipótese nula, uma vez que o p-valor é menor do que o nível de significância alfa de 5%. Em

outras palavras, há evidências estatísticas para recusarmos que a média das notas para as 3 plataformas são iguais, independente de qual foi a plataforma escolhida. Uma vez testado e confirmado que as médias nas 3 plataformas são diferentes, abaixo iremos investigar dois a dois as médias entre as plataformas.

- **Teste de Wilcoxon pareado (Comparação de médias dois a dois)**

Grupo 1: grupo que escolheu a plataforma 1

TABELA 16 - Teste de Wilcoxon pareado - Grupo 1

	Notas		
Notas	Nota 1	Nota 2	Nota 3
Nota 1	1	1	1
Nota 2	-	1	0,8426
Nota 3	-	0,1607	1

Fonte: Elaboração própria (2019).

H0: Média 1 = Média 2 = Média 3

H1: Média 1 < Média 2

H2: Média 2 < Média 3

Evidenciado que a média da nota das plataformas são diferentes dependendo da plataforma escolhida é possível realizar um teste para se entender qual é a preferência demonstrada na intenção de compra quando a nota dada a experiência nas plataformas é igual.

O teste de Wilcoxon pareado é utilizado para comparar se as medidas de posição de duas amostras são iguais no caso em que as amostras são dependentes. Para todos os casos em que o p-valor é maior do que 0,05, não rejeitamos a hipótese nula, pois não há evidências estatística para acreditar que as médias dessas plataformas não diferem.

Grupo 2: grupo que escolheu a plataforma 2

TABELA 17 - Teste de Wilcoxon pareado - Grupo 2

	Notas		
Notas	Nota 1	Nota 2	Nota 3
Nota 1	1	<0,001	0,006
Nota 2	-	1	1
Nota 3	-	<0,001	1

Fonte: Elaboração própria (2019).

H0: Média 1 = Média 2 = Média 3

H1: Média 1 < Média 2

H2: Média 2 < Média 3

Plataforma 1 e 2

H0: Média 1 = Média 2

H1: Média 1 < Média 2

Considerando um nível de confiança de 5% e analisando os p-valores acima, há evidências estatísticas para rejeitarmos a hipótese nula de que as médias são iguais. Assim ficamos com a hipótese alternativa de que a média da nota para a experiência do usuário na plataforma 2 foi maior do que a da plataforma 1, para quem escolheu a plataforma 2.

Plataforma 2 e 3

H0: Média 2 = Média 3

H1: Média 2 < Média 3

Considerando um nível de confiança de 5% e analisando os p-valores acima, não há evidências estatísticas para rejeitarmos a hipótese nula de que as médias são iguais. Assim ficamos com a hipótese nula de que a média da nota para a experiência do usuário na plataforma 2 foi igual a da plataforma 3, para quem escolheu a plataforma 2.

Grupo 3: grupo que escolheu a plataforma 3

TABELA 18 Teste de Wilcoxon pareado - Grupo 3

	Notas		
Notas	Nota 1	Nota 2	Nota 3
Nota 1	1	<0,001	<0,001
Nota 2	-	1	<0,001
Nota 3	-	1	1

Fonte: Elaboração própria (2019).

H0: Média 1 = Média 2 = Média 3

H1: Média 1 < Média 2

H2: Média 2 < Média 3

Plataforma 1 e 2

H0: Média 1 = Média 2

H1: Média 1 < Média 2

Considerando um nível de confiança de 5% e analisando os p-valores acima, há evidências estatísticas para rejeitarmos a hipótese nula de que as médias são iguais. Assim

ficamos com a hipótese alternativa de que a média da nota para a experiência do usuário na plataforma 2 foi maior do que a da plataforma 1, para quem escolheu a plataforma 3.

Plataforma 2 e 3

H0: Média 2 = Média 3

H1: Média 2 < Média 3

Considerando um nível de confiança de 5% e analisando os p-valores acima, há evidências estatísticas para rejeitarmos a hipótese nula de que as médias são iguais. Assim ficamos com a hipótese alternativa de que a média da nota para a experiência do usuário para a plataforma 3 foi maior do que a da plataforma 2, para quem escolheu a plataforma 3.

A partir dos resultados coletados observa-se que a plataforma 2 sinalizou majoritariamente um reforço informativo, uma vez que ajudava o indivíduo a se reforçar na sociedade por meio da cultura cinematográfica, e a plataforma 3 acabava exercendo um efeito e reforço utilitário, uma vez que era a plataforma em que o usuário de fato recebia filmes de sua preferência pessoal no menu de películas. Com o resultado obtido na 17 pode-se relacionar que grande parte dos respondentes utiliza plataformas de streaming para se inserir socialmente, uma vez que os filmes *blockbusters* (apresentados na plataforma 2) foram preferidos em relação a plataforma 3, que ironicamente era exatamente o que a pessoa declarou mais gostar.

5 CONCLUSÃO

O presente estudo teve como objetivo final descobrir se plataformas com algoritmos personalizados possuem um maior desempenho no quesito experiência do usuário e intenção de compra comparado as plataformas que não possuem algoritmos personalizados. Além disto, foi verificado se características como perfil demográfico e perfil de uso de plataformas similares, Youtube e Netflix, influenciavam na tomada de decisão em relação ao voto em cada plataforma e a escolha da plataforma na qual assinaria.

Foi averiguado que tanto o perfil demográfico quanto o perfil de uso não possuem relevância para a escolha da plataforma preferida e para a nota dada as plataformas. Além disso, constatou-se que a nota dada pela mesma pessoa antes e depois de analisar todas as plataformas não difere significativamente.

Já em relação às plataformas a hipótese levantada de que quanto mais personalizada, mais envolvida a pessoa fica com a plataforma foi sustentada ao testar as médias par a par, checando que a plataforma 3 (a mais personalizada) se destaca em relação às plataformas 1 e 2 tanto no quesito experiência do usuário, quanto no quesito intenção de compra, que foram as duas variáveis dependentes propostas pelo modelo.

Também se pode concluir que a plataforma 2 (médio personalizada) em relação a plataforma 1 (nada personalizada) obteve melhores pontuações nos quesitos experiência do usuário e intenção de compra.

Quando rodado os testes para averiguar se a nota dada a experiência do usuário influenciava na intenção de compra, conclui-se que quem escolhe a plataforma 2, avalia melhor a plataforma 2 do que a 1, mas quem dá notas iguais a plataforma 2 e 3, escolhe a 2. Quem escolhe plataforma 3, avalia melhor a plataforma 2 do que a 1, mas quem avalia melhor a plataforma 3 em relação a 2, escolhe a 3.

A informação mais inesperada dessa amostragem é que era esperado que pessoas que dessem a mesma nota pras plataformas 2 e 3 escolhessem a 3, visto que ela era mais

personalizada, porém o resultado se configurou ao contrário. Algumas hipóteses podem surgir desse resultado: a primeira delas é que talvez pessoas gostem de ver as opções mais famosas e de grande bilheteria disponíveis, pois de certa forma isso é um reforço informativo na sociedade, logo uma plataforma personalizada com os gostos gerais tende a agradar muitas pessoas que buscam por meio de filmes se incluir socialmente, talvez até prefiram saber quais são as novidades, mesmo que essa sugestão de filmes não esteja alinhada a seus gostos pessoais. A segunda hipótese é que o respondente pode não ter visto muitas diferenças entre as plataformas 2 e 3 e assim escolheu aleatoriamente a plataforma 2. Existem outras hipóteses a serem testadas para se entender este dado, surgindo então um novo tema de pesquisa acerca do experimento.

Observou-se que as plataformas de streaming geraram tanto reforços informativos quanto utilitários e isso ficou evidenciado quando comparada a média dois a dois da plataforma 2 e 3. Portanto quando analisado a luz do modelo BPM de Foyal é possível identificar que os algoritmos de personalização influenciam no cenário de consumo, uma vez que personalização do conteúdo nas plataformas de vídeo propicia que seja entregue ao indivíduo o conteúdo relacionado ao seu contexto de inserção na sociedade, e além disso esses algoritmos mapeiam o histórico de aprendizagem do consumidor para assim manipular as ofertas que serão feitas nos canais, tendo como exemplo os vídeos no Youtube, que ao sinalizar a punição utilitária por meio do “não gostei” a plataforma processa essa informação, joga no seu histórico e passa a partir daquele momento a não entregar ao usuários aquele tipo de conteúdo já sinalizado como não interessante.

As limitações da pesquisa se concentraram em alguns aspectos: primeiramente em relação à quantidade baixa de dados que foram retirados da API em relação aos filmes, uma vez que era preciso ser uma API com dados confiáveis, logo a plataforma conseguiu configurar uma personalização, mas que ainda sim é irrisória comparado ao grau de personalização da Netflix, por exemplo; a segunda limitação foi em relação ao algoritmo, pois a criação de um algoritmo de personalização sem a existência de assinantes de fato para a coleta de seus dados na plataforma acaba restringindo a criação dos algoritmos nas poucas perguntas que foram feitas no questionário; a terceira limitação a ser corrigida em futuros estudos é que não foram colocadas as plataformas em ordem aleatória dentro do experimento, desta forma é possível que tenha ficado

mais evidente a crescente de personalização ao decorrer do experimento e até enviesado a opinião de alguns.

Para futuras pesquisas sugere-se testar as estratégias de algoritmos de personalização com empresas reais, para que se possa ter um ponto de partida com dados já coletados de seus usuários e assim construir um algoritmo mais completo e que tenha um auto aprendizado, assim acrescentando variáveis a medida que o consumidor for de fato utilizando a plataforma de entretenimento. Além disso, sugere-se fazer um grupo focal para analisar as percepções cara a cara dos telespectadores ao mexer na plataforma, pois assim é possível tirar mais conclusões acerca da experiência do usuário em cada uma delas.

REFERÊNCIAS

ADTHEORENT. **Artificial Intelligence Roundup**. Maio 2018. Disponível em: <http://files.r-trends.ru/reports/eMarketer_Roundup_Artificial_Intelligence_2018_2.pdf>. Acesso em: 10 out. 2019.

BRASIL. **Agenda brasileira para a Indústria 4.0**: O Brasil preparado para os desafios do futuro. [s.d.]. Disponível em: <<http://industria40.gov.br/>>. Acesso em: 10 out. 2019.

_____. Lei nº 13.709, de 14 de agosto de 2018. **Lei Geral de Proteção de Dados Pessoais (LGPD) editada pela Lei nº 13.853, de 2019**. Brasília, ago. 2018. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/L13709.htm#art65..>. Acesso em: 10 out. 2019.

BRASSCOM. **Relatório Setorial de TIC 2019**. 2019. Disponível em: <<https://brasscom.org.br/relatorio-setorial-de-tic-2019/>>. Acesso em: 10 out. 2019.

CHAU, P. Y. K. et al. Examining the effects of malfunctioning personalized services on online users' distrust and behaviors. **Decision Support Systems**, Amsterdam, v. 56, p. 180-191, Dez 2013.

DILLMAN, D. A.; FREY, J. H. Contribution of personalization to mail questionnaire response as an element of a previously tested method. **Journal of Applied Psychology**, v. 59, n. 3, p. 297-301, 1974.

MCCLAY, M. Survey Report: Trends & Priorities in Real-Time Personalization. **Evergage**, jun. 2015. Disponível em: <<https://www.evergage.com/blog/survey-findings-trends-priorities-in-real-time-personalization/>>. Acesso em: 10 out. 2019.

EREVELLES, S.; FUKAWA, N.; SWAYNE, L. Big data consumer analytics and the transformation of marketing. **Journal of Business Research**, v. 69, n. 2, p. 897-904, 2016.

FOXALL, G. R. The Behavioral Perspective Model of Purchase and Consumption: From Consumer Theory. **Journal of the Academy of Marketing Science**, v. 20, n. 2, p. 189-198, 1992.

FOXALL, G. R. et al. Consumer behaviour analysis and the behavioural perspective model. **Management Online Review (MORE)**, p. 1-9, 2011.

FREITAG, E. A. **E quando a personalização não dá certo?** Fatores que influenciam negativamente a percepção do consumidor em relação à personalização online. Monografia (Graduação em Administração). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

HERMANN, M.; PENTEK, T.; OTTO, B. Design Principles for Industrie 4.0 Scenarios: A Literature Review. **Technische Universität Dortmund**, p. 11-13, 2015.

HOFACKER, C.; MALTHOUSE, E.; SULTAN, F. Big Data and consumer behavior: imminent opportunities. **Journal of Consumer Marketing**, v. 33, n. 2, p. 89-97, 2016.

JACOBY, J.; JOHAR, G. V.; MORRIN, M. Consumer behavior: a quadrennium. **Annual Review of Psychology**, 49, 319-344, 1998.

KAGERMANN, H.; WAHLSTER, W.; HELBIG, J. Recommendations for implementing the strategic initiative INDUSTRIE 4.0. Final report of the Industrie 4.0 Working Group. **Acatech – German Academy of Science and Engineering**. 2013.

KOMIAK, S. Y. X.; BENBASAT, I. The effects of personalization and familiarity on trust and adoption of recommendation agents. **MIS Quarterly**, Minnesota, v. 30, n. 4, p. 941-960, dez. 2006.

LANEY, D. 3D data management: Controlling data volume, velocity and variety. **Application Delivery Strategies - Meta Group**, 6 Feb, 949, 2001.

LAVIE, T. et al. User Attitudes Towards News Content Personalization. **International Journal of Human-Computer Studies**, Duluth, v. 69, n. 8, p. 483-495, ago. 2010.

LEE, S.; LEE, Y.; LEE, J. Personalized E-services: consumer privacy concern and information sharing. **Social Behavior & Personality: an international journal**, v. 43, n. 5, p. 729 - 740, jun. 2015.

MUSILLI, C. Indústria cinematográfica registra lucro recorde em 2018. **Folha de Londrina**, mar. 2019. Disponível em: <<https://www.folhadelondrina.com.br/folha-2/industria-cinematografica-registra-lucro-recorde-em-2018-2936547e.html>>. Acesso em: 10 out. 2019.

Pequenas Empresas & Grandes Negócios. **Esta fazenda é completamente controlada por robôs**. 2019. Disponível em: <https://revistapegn.globo.com/Banco-de-ideias/Econegocio/noticia/2019/05/esta-fazenda-e-totalmente-controlada-por-robos.html?utm_source=linkedin&utm_medium=social&utm_campaign=post>. Acesso em: 10 set. 2019.

PROVOKERS. **Pesquisa Video Viewers**: como os brasileiros estão consumindo vídeos em 2018. 2018. Disponível em: <<https://trello-attachments.s3.amazonaws.com/5cb4b02305980c3331f0b14f/5cb4b0ed3adfd2170>>

6cbfead/26c50489412702b5955c706ff5e5c5e9/twg_videoviewers_infographic.pdf>. Acesso em: 4 out. 2019.

POHL, R. H.; OLIVEIRA-CASTRO, J. M. **Efeitos do Nível de Benefício Informativo das Marcas sobre a Duração do Comportamento de Procura**. Dissertação (Mestrado em Psicologia). Universidade de Brasília, Brasília, 2008.

PORTO, R. B.; OLIVEIRA-CASTRO, J. Consumer Purchase and Brand Performance: The Basis of Brand Market Structure. In: FOXALL, G. **The Routledge Companion to Consumer Behavior Analysis**. Oxfordshire: Routledge, 2015.

PWC - Pricewaterhouse Coopers. **19º Pesquisa Global de Entretenimento e Mídia 2018-2022**. 2019. Disponível em: <<https://www.pwc.com.br/pt/outlook-18.html>>. Acesso em: 20 out. 2019.

REIS, A. C. B. C. dos et al. Marketing de relacionamento: agregando valor ao negócio com Big Data. **REMark, Revista Brasileira de Marketing**, edição especial v. 15, n. 4, nov. 2016.

ROYER, R.; SANTOS, G. T. A Função Marketing no Paradigma da Personalização de Produtos e Serviços e da Customização em Massa. **Revista do Instituto de Ciências Econômicas, Administrativas e Contábeis - ICEAAC**, v. 14, n. 2, 2010.

SKINNER, B. F. **Science and human behavior**. New York: Macmillan, 1953.

SOLOMON, M. R. **O Comportamento do consumidor: comprando, possuindo e sendo**. 5.ed. Porto Alegre: Bookman, 2002.

STERNE, J. **Artificial Intelligence for Marketing: Practical Applications**. Hoboken, New Jersey, 2017.

TAM, K. Y.; HO, S. Y. Understanding the Impact of Web Personalization on User Information Processing and Decision Outcomes. **MIS Quarterly**, Minneapolis, v.30, n.4, p. 865-890, dez. 2006.

VESANEN, J. What is personalization? A conceptual framework. **European Journal of Marketing**, v. 41, n. 5/6, p. 409-418, 2007.

APÊNDICE

Abaixo encontra-se o código utilizado para viabilizar o experimento, no qual foi hospedado em uma página web.

```
import { BASE_IMDB_API, IMDB_API_KEY } from 'config/consts';
import axios from 'axios'; import { genresNamesList } from
'./config/consts'; import { shuffle } from
'helpers/dataTransformers'; var Airtable = require('airtable');

Airtable.configure({
  endpointUrl: 'https://api.airtable.com', apiKey:
'key7Acef9geH3sxf9' }); var base =
Airtable.base('app7j9tl0ae1ErYX5');

export const getPlatform1MoviesList = () => {
  let array150 = []; let
  list0 = [], list1 = [],
  list2 = [], list3 = [],
  list4 = [], list5 = [],
  list6 = [], list7 = [],
  list8 = [], list9 = [],
  list10 = []; return
  dispatch => {
    dispatch({
      type: 'PLATFORM1_MOVIES_LOAD',
      payload: true }); base('Filmes')
      .select({
        // Selecting the first 3 records in Grid view:
        maxRecords: 150, view: 'Grid view' })
      .eachPage(
        function page(records, fetchNextPage) {
          // This function (`page`) will get called for each page of records.
```

```

records.forEach(function(record) {
array150 = [...array150, record.fields]; });

// To fetch the next page of records, call `fetchNextPage`. // If
there are more records, `page` will get called again. // If there
are no more records, `done` will get called. fetchNextPage();

if (array150.length === 150) {
const shuffledGenreNamesList = shuffle(genresNamesList); list0 =
shuffle(array150).slice(0, 15); const shuffledArray150 =
shuffle(array150);

shuffledGenreNamesList.map((shuffledItem, shuffledIndex) => {
return shuffledArray150.map((array150item, array150index) => {
if (shuffledItem === array150item.genre_name) {
if (list1.length !== 15) {
list1.push(array150item); } else if
(list2.length !== 15) {
list2.push(array150item); } else if
(list3.length !== 15) {
list3.push(array150item); } else if
(list4.length !== 15) {
list4.push(array150item); } else if
(list5.length !== 15) {
list5.push(array150item); } else if
(list6.length !== 15) {
list6.push(array150item); } else if
(list7.length !== 15) {
list7.push(array150item); } else if
(list8.length !== 15) {
list8.push(array150item); } else if
(list9.length !== 15) {
list9.push(array150item); } else if
(list10.length !== 15) {
list10.push(array150item); } } } }); });

dispatch({
type: 'PLATFORM1_MOVIES_FETCHED', payload: { list1, list2, list3, list4,
list5, list6, list7, list8, list9, list10 } }); }, function done(err) {
if (err) {

```

```

console.error(err); return; } } ); }; }; export

const getPlatform2MoviesList = () => {
let array150 = []; let
list0 = [], list1 = [],
list2 = [], list3 = [],
list4 = [], list5 = [],
list6 = [], list7 = [],
list8 = [], list9 = [],
list10 = []; return
dispatch => {
dispatch({
type: 'PLATFORM2_MOVIES_LOAD',
payload: true }); base('Filmes')
.select({
// Selecting the first 3 records in Grid view:
maxRecords: 150,
view: 'Grid view' })
.eachPage(
function page(records, fetchNextPage) {
// This function (`page`) will get called for each page of records.

records.forEach(function(record) {
array150 = [...array150, record.fields]; });

// To fetch the next page of records, call `fetchNextPage`. // If
there are more records, `page` will get called again. // If there
are no more records, `done` will get called. fetchNextPage();

//Coloca em ordem decrescente de avaliação if
(array150.length === 150) {
const shuffledGenreNamesList = shuffle(genresNamesList); list0 =
[
...array150.sort(function(a, b) {
if (b.title === a.title) {
return 0; } return b.vote_average -
a.vote_average; }) ];

//Tira os repetidos let
counterRepeated = 0; let j = 0;
let i = 0; while (j < list0.length) {

```

```

counterRepeated = 0; i = 0;
while (i < list0.length) {
  if (list0[i].title === list0[j].title) {
    counterRepeated = counterRepeated + 1; if
(counterRepeated > 1) { } } i++; }

if (counterRepeated > 1) {
  list0.splice(j, 1); } else { j++; } }
list0 = [...list0.slice(0, 15)];

const shuffledArray150 = shuffle(array150);

shuffledGenreNamesList.map((shuffledItem, shuffledIndex) => {
  return shuffledArray150.map((array150item, array150index) => {
    if (shuffledItem === array150item.genre_name) {
      if (list1.length !== 15) {
        list1.push(array150item); } else if
        (list2.length !== 15) {
list2.push(array150item);
} else if (list3.length !== 15) {
  list3.push(array150item); } else if
  (list4.length !== 15) {
list4.push(array150item); } else if
  (list5.length !== 15) {
list5.push(array150item); } else if
  (list6.length !== 15) {
list6.push(array150item); } else if
  (list7.length !== 15) {
list7.push(array150item); } else if
  (list8.length !== 15) {
list8.push(array150item); } else if
  (list9.length !== 15) {
list9.push(array150item); } else if
(list10.length !== 15) {
list10.push(array150item); } } } });

list1 = [
...list1.sort(function(a, b) {
return b.vote_average - a.vote_average; }) ];

list2 = [

```

```

...list2.sort(function(a, b) {
return b.vote_average - a.vote_average; });

list3 = [
...list3.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list4
= [
...list4.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list5
= [
...list5.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list6
= [
...list6.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list7
= [
...list7.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list8
= [
...list8.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list9
= [
...list9.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list10
= [
...list10.sort(function(a, b) {
return b.vote_average - a.vote_average; });

dispatch({
type: 'PLATFORM2_MOVIES_FETCHED', payload: { list1, list2, list3, list4,
list5, list6, list7, list8, list9, list10 } }); }, function done(err) {
if (err) {

console.error(err); return; } } ); }; export const

getPlatform3MoviesList = formValues => {
let array150 = []; let
list0 = [], list1 = [],
list2 = [], list3 = [],
list4 = [], list5 = [],
list6 = [], list7 = [],

```

```

list8 = [], list9 = [],
list10 = []; return
dispatch => {
dispatch({
type: 'PLATFORM3_MOVIES_LOAD',
payload: true }); base('Filmes')
.select({
// Selecting the first 3 records in Grid view:
maxRecords: 150, view: 'Grid view' })
.eachPage(
function page(records, fetchNextPage) {
// This function (`page`) will get called for each page of records.

records.forEach(function(record) {
array150 = [...array150, record.fields];
});

// To fetch the next page of records, call `fetchNextPage`. // If
there are more records, `page` will get called again. // If there
are no more records, `done` will get called. fetchNextPage();

if (array150.length === 150) {
//Tira os gêneros selecionados da lista normal let newGenresNamesList = [...genresNamesList];
newGenresNamesList.splice(genresNamesList.indexOf(formValues.firstGenre), 1);
newGenresNamesList.splice(newGenresNamesList.indexOf(formValues.secondGenre), 1);
newGenresNamesList.splice(newGenresNamesList.indexOf(formValues.thirdGenre), 1);

//Adiciona os gêneros selecionados em outra lista let
recomendationGenres = [];
recomendationGenres.push(formValues.firstGenre);
recomendationGenres.push(formValues.secondGenre);
recomendationGenres.push(formValues.thirdGenre);

//Adiciona os filmes de cada gênero (dos selecionados) em suas respectivas listas (1,2 e 3)
recomendationGenres.map((shuffledItem, shuffledIndex) => {
return array150.map((array150item, array150index) => {
if (shuffledItem === array150item.genre_name) {
if (list1.length !== 15) {
list1.push(array150item); } else if
(list2.length !== 15) {
list2.push(array150item); } else if
(list3.length !== 15) {

```

```

list3.push(array150item); } } }); });

//Reordena os filmes das listas 1,2 e 3 list1 = [
...list1.sort(function(a, b) {
return b.vote_average - a.vote_average; }]); list2
= [
...list2.sort(function(a, b) {
return b.vote_average - a.vote_average; }]); list3
= [
...list3.sort(function(a, b) {
return b.vote_average - a.vote_average; }]);

//Adiciona os gêneros odiados em outra lista let
hatedGenres = [];
hatedGenres.push(formValues.lastGenre);
hatedGenres.push(formValues.secondLastGenre);

//Adiciona os filmes de cada gênero (dos selecionados) em suas respectivas listas (10 e 9)
hatedGenres.map((shuffledItem, shuffledIndex) => {
return array150.map((array150item, array150index) => {
if (shuffledItem === array150item.genre_name) {
if (list10.length !== 15) {
list10.push(array150item); } else if
(list9.length !== 15) {
list9.push(array150item); } } } }); });

//Reordena os filmes das listas 10 e 9 let
list12 = [
...list10.sort(function(a, b) {
return b.vote_average - a.vote_average; }]); let
list11 = [
...list9.sort(function(a, b) {
return b.vote_average - a.vote_average; }]);

//Ordenação let
nonRepeated150 = [
...array150.sort(function(a, b) {
if (b.title === a.title) {
return 0; } return b.vote_average -
a.vote_average; }]);

//Repetição let counterRepeated = 0; let j =

```

```

0; let i = 0; while (j <
nonRepeated150.length) {
counterRepeated = 0; i = 0; while (i <
nonRepeated150.length) {
if (nonRepeated150[i].title === nonRepeated150[j].title) {
counterRepeated = counterRepeated + 1; } i++; }

if (counterRepeated > 1) {
nonRepeated150.splice(j, 1); } else {
j++; } }

let variavel = 'Recentes'; let
list0_1 = []; let list0_2 = []; let
list0_3 = []; let tempArray = [];
[0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0].map((templtem, tempIndex) => {
if (list0_1.length === 5 && list0_2.length === 5 && list0_3.length === 5) { } else {
list0_1 = []; list0_2 = []; list0_3 = []; tempArray = [];
shuffle(nonRepeated150).map((item, index) => {
if (!tempArray.includes(item.title)) {
if (variavel === 'Recentes') {
if (
item.genre_name === formValues.firstGenre && list0_1.length
!== 5 && item.release_date.split('-')[0] >= 2005 ) {
list0_1.push(item); } else if (
item.genre_name === formValues.secondGenre && list0_2.length
!== 5 && item.release_date.split('-')[0] >= 2005 ) {
list0_2.push(item); } else if (
item.genre_name === formValues.thirdGenre && list0_3.length
!== 5 && item.release_date.split('-')[0] >= 2005 ) {
list0_3.push(item); } } else if (variavel ===
'Antigos') {
if (
item.genre_name === formValues.firstGenre && list0_1.length
!== 5 && item.release_date.split('-')[0] < 2005 ) {
list0_1.push(item); } else if (
item.genre_name === formValues.secondGenre && list0_2.length
!== 5 && item.release_date.split('-')[0] < 2005 ) {
list0_2.push(item); } else if (
item.genre_name === formValues.thirdGenre && list0_3.length
!== 5 && item.release_date.split('-')[0] < 2005 ) {
list0_3.push(item); } } else { } }

```

```

tempArray.push(item.title); });

if (list0_1.length < 5) {
  nonRepeated150.map((item, index) => {
    if (!tempArray.includes(item.title)) {
      if (item.genre_name === formValues.firstGenre && list0_1.length !== 5) {
        list0_1.push(item); } }
      tempArray.push(item.title); }); } if
(list0_2.length < 5) {
  nonRepeated150.map((item, index) => {
    if (!tempArray.includes(item.title)) {
      if (item.genre_name === formValues.secondGenre && list0_2.length !== 5) {
        list0_2.push(item); } }
      tempArray.push(item.title); }); } if
(list0_3.length < 5) {
  nonRepeated150.map((item, index) => {
    if (!tempArray.includes(item.title)) {
      if (item.genre_name === formValues.thirdGenre && list0_3.length !== 5) {
        list0_3.push(item); } }
      tempArray.push(item.title); }); } } });

list0 = [...list0_1, ...list0_2, ...list0_3]; nonRepeated150 =
[...nonRepeated150.slice(0, 15)];

const shuffledArray150 = shuffle(array150); const
shuffledGenreNamesList = shuffle(newGenresNamesList); list9 = [];
list10 = []; shuffledGenreNamesList.map((shuffledItem, shuffledIndex)
=> {
  return shuffledArray150.map((array150item, array150index) => {
    if (shuffledItem === array150item.genre_name) {
      if (list4.length !== 15) {
        list4.push(array150item); } else if
          (list5.length !== 15) {
            list5.push(array150item); } else if
              (list6.length !== 15) {
                list6.push(array150item); } else if
                  (list7.length !== 15) {
                    list7.push(array150item); } else if
                      (list8.length !== 15) {
                        list8.push(array150item); } else if
                          (list9.length !== 15) {

```

```

list9.push(array150item); } else if
(list10.length !== 15) {
list10.push(array150item); } } }); });

list4 = [
...list4.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list5
= [
...list5.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list6
= [
...list6.sort(function(a, b) {
return b.vote_average - a.vote_average; }); list7
= [
...list7.sort(function(a, b) {
return b.vote_average - a.vote_average; });

list8 = [
...list8.sort(function(a, b) {
return b.vote_average - a.vote_average; });

list9 = [
...list9.sort(function(a, b) {
return b.vote_average - a.vote_average; });

list10 = [
...list10.sort(function(a, b) {
return b.vote_average - a.vote_average; });

let finalArray = [list1, list2, list3, list4, list5, list6, list7, list8, list9, list10]; let
finalArray3 = finalArray.filter((item, index) => {
return !(item[0].genre_id == list11[0].genre_id || item[0].genre_id == list12[0].genre_id); });

dispatch({
type: 'PLATFORM3_MOVIES_FETCHED',
payload: {
list0, list1: finalArray3[0],
list2: finalArray3[1], list3:
finalArray3[2], list4:
finalArray3[3], list5:
finalArray3[4], list6:

```

```

finalArray3[5], list7:
finalArray3[6], list8:
finalArray3[7] } }]); } }, function
done(err) {
if (err) {

console.error(err); return; } } ); }; }; export const sendRating

= (values, router = undefined) => {
return dispatch => {
base('Respostas').create(
[
{
fields: {
Idade: values.age, Gênero: values.gender, Renda:
values.revenue, Escolaridade: values.escolarity, 'Anos
de Youtube': values.years_yt, 'Horas de Youtube':
values.time_week_yt, 'Anos de Netflix':
values.years_nf, 'Horas de Netflix':
values.time_week_nf, 'Nota 1': values.rating_1, 'Nota 2':
values.rating_2, 'Nota 3': values.rating_3, 'Qual
assinaria': values.sign_one, '1o Colocado':
values.firstGenre, '2o Colocado': values.secondGenre,
'3o Colocado': values.thirdGenre, 'Antigo ou recente':
values.recent, 'Nota 1 antes': values.before_rating_1,
'Nota 2 antes': values.before_rating_2, 'Nota 3 antes':
values.before_rating_3, 'Último Colocado':
values.lastGenre, 'Penúltimo Colocado':
values.secondLastGenre } } ], function(err, records) {
if (err) {
console.error(err); return; }
records.forEach(function(record) { });

if (router) {
router.push('/obrigado'); } } ); }; };

export const getMovies = async () => {
let j = 0,
fullArray = [], repeatedTitle = []; return async
dispatch => {
dispatch({ type: 'MOVIES_LOAD', payload: true });

```

```

//Roda até todas as listas de gêneros possuírem pelo menos 15 filmes let
randomArray = []; while (j < 15) {
// Gera número aleatório para página da requisição let
random = Math.floor(Math.random() * 50 + 1); if
(randomArray.includes(random)) { } else {
// Realiza requisição da página especificada let response = await
axios.get(`${BASE_IMDB_API}movie/popular/?api_key=${
{IMDB_API_KEY}&page=${random}`);
repeatedTitle = [];

// Itera pelos IDs dos gêneros pré-determinados [10749, 878, 16, 35, 80, 9648,
18, 27, 12, 28].map((genreId, mapIndex) => {
// Retorna somente os itens da requisição que possuem algum dos IDs dos gêneros let
tempArray = [];

for (let d = 0; d < response.data.results.length; d++) {
if (response.data.results[d].genre_ids.includes(genreId)) {
if (response.data.results[d].release_date) {
let tempDate = response.data.results[d].release_date; let tempDateSplit =
tempDate.split('-')[0]; if (response.data.results[d].adult === false &&
tempDateSplit !== 2019) {
if (!repeatedTitle.includes(response.data.results[d].title)) {
tempArray.push(response.data.results[d]);
repeatedTitle.push(response.data.results[d].title); } } } }

const tempArray2 = tempArray.map((filterItem, filterIndex) => {
let genreSize = filterItem.genre_ids.length; for (let
i = 0; i < genreSize; i++) {
if (filterItem.genre_ids[i] === genreId) {
let newFilterItem = {
...filterItem, overview: filterItem.overview.replace(/"/g, "")
}; return {
...newFilterItem, genre_id: genreId, overview:
newFilterItem.overview.replace(/,/g, ';'), genre_name:
genreId === 28
? 'Ação' : genreId === 16 ?
'Animação' : genreId === 12 ?
'Aventura' : genreId === 35 ?
'Comédia' : genreId === 80 ?
'Crime' : genreId === 9648 ?
'Mistério' : genreId === 18

```

```

? 'Drama' : genreId === 878 ?
'Ficção' : genreId === 10749 ?
'Romance' : genreId === 27 ?
'Terror' : 'N/A' }; } } });

// Coloca a lista no array
fullArray[mapIndex].push(...tempArray2);

// Verificação para que todas as listas de gênero possuam pelo menos 15 filmes if
(mapIndex === 0) {
j = fullArray[mapIndex].length; } if (j >
fullArray[mapIndex].length) {
j = fullArray[mapIndex].length; } });

// Contador de requisições }
randomArray.push(random); }

// Tratamento do array de filmes, para que todos possuam exatamente 15 filmes let
finalArray = fullArray.map((item, index) => {
return item.slice(0, 15); });

let payloadArray = []; let tempArray =
finalArray.map((item, index) => {
payloadArray = [...payloadArray, ...item];
return [...item]; });

dispatch([
{
type: 'MOVIES_FETCHED',
payload: payloadArray } ]); } });

```