

## **EFEITOS DA PERSONALIZAÇÃO DE CONTEÚDO EM PLATAFORMA DE VÍDEO ONLINE**

**NATALIA GUARANY BONETTI**  
UNIVERSIDADE DE BRASÍLIA (UNB)

**CARLA BORGES**  
UNIVERSIDADE DE BRASÍLIA (UNB)

**JORGE MENDES DE OLIVEIRA CASTRO NETO**  
UNIVERSIDADE DE BRASÍLIA (UNB)

Agradecimento à órgão de fomento:

Agradecemos a CNPQ e a CAPES por fomentarem a pesquisa no Brasil e a Universidade de Brasília pelo apoio por meio de laboratórios.

# EFEITOS DA PERSONALIZAÇÃO DE CONTEÚDO EM PLATAFORMA DE VÍDEO ONLINE

## 1. INTRODUÇÃO

O Relatório Setorial de TIC 2019, produzido pela Associação Brasileira das Empresas de Tecnologia da Informação e Comunicação (Brasscom, 2019) prevê um investimento de R\$ 345,5 bilhões em tecnologias de transformação digital até 2022. Esse volume de investimentos é característico da quarta revolução industrial, marcada por um conjunto de tecnologias que permitem a simbiose do mundo físico, digital e biológico, destacando-se o foco na personalização de produtos para o consumidor (Kagermann et al., 2013). Um setor relevante no contexto da transformação digital é o de entretenimento, em especial o das plataformas digitais de streaming, que vem apresentando crescimento acelerado em investimentos, segundo a 19ª Pesquisa Global de Entretenimento e Mídia 2018-2022 (REF). Dados de 2019 e 2020 mostram que, em 12 meses, saltou de 38% para 51% a proporção de internautas brasileiros que assinam plataformas de streaming de filmes ou séries (Panorama Mobile Time/Opinion Box, 2020), classificadas provedoras de serviços Over-The-Top (OTT) (Price Waterhouse Coopers, 2018). De acordo com a Anatel, as OTTs são "aplicações acessadas ou entregues na rede pública que podem substituir de forma direta ou funcional os serviços de telecomunicações tradicionais". Viana (2020) destaca que as OTTs são "canais digitais de transmissão de áudio e vídeo que podem ser personalizados para cada cliente, de acordo com as suas preferências", o que vem se tornando possível graças ao uso das tecnologias de inteligência artificial. Casos de plataformas como Netflix (2020) e Youtube vêm chamando a atenção do mercado pela adoção de estratégias de personalização de conteúdo a partir de análises de dados dos consumidores com o uso desse tipo de tecnologia (e.g., MARR, 2016; MADDODI et al., 2019; BELLANOVA, GONZÁLEZ FUSTER, 2018; PROVOKERS, 2018). Segundo pesquisa realizada pela Evergage (Freitag, 2016) 91% das empresas no meio online usam ou pretendem adotar esse tipo de estratégia.

## 2. PROBLEMA E OBJETIVOS

Nota-se, portanto, que a implementação de tecnologias envolvendo Inteligência Artificial vem transformando as estratégias de marketing (EREVELLES et al., 2016; PEARSON, 2019), uma vez que as empresas conseguem adquirir mais informações sobre seus públicos, tornando mais fácil o entendimento de padrões de compra e preferências de seus consumidores. Por isso, a personalização de conteúdo a partir do uso de algoritmos de Inteligência Artificial tem se tornado uma usual estratégia para as OTTs.

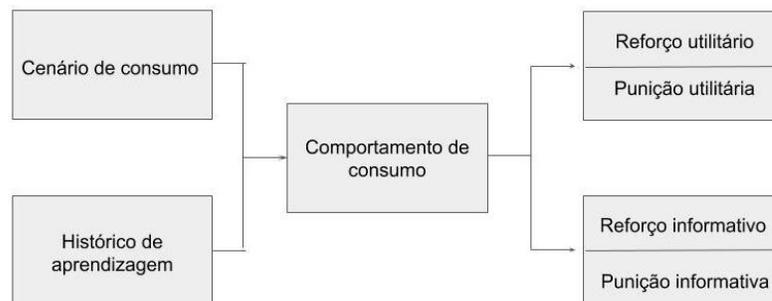
Do ponto de vista acadêmico, no entanto, a análise dos efeitos de estratégias de personalização em serviços OTT carece de pesquisas experimentais. Assim, esse conhecimento acaba restrito às organizações que praticam a estratégia, as quais adotam suas próprias formas de controle de resultados. Diante dessa lacuna buscou-se, como

objetivo, analisar os efeitos de uma estratégia de personalização de um portfólio de vídeos ofertados por um serviço OTT simulado sobre reações de potenciais consumidores. Foram comparadas as reações dos consumidores à oferta de um portfólio de vídeos personalizado com dois outros portfólios, um composto aleatoriamente, e outro composto a partir da seleção de filmes com melhor desempenho em bilheterias. Como problema de pesquisa, buscou-se responder se cenários com maior personalização apresentam melhor relação com a experiência do usuário e se a personalização aumenta a frequência de relatos de intenção de compra.

### 3. FUNDAMENTAÇÃO TEÓRICA

Na visão analítico-comportamental (G. R. Foxall, 1998; G. R. Foxall & James, 2001; Skinner, 1985), o comportamento de consumo pode ser analisado como o conjunto de comportamentos a partir dos quais os consumidores interagem com o ambiente para obter acesso aos bens de consumo e serviços. Nessa interação, destacam-se as relações e influências recíprocas entre empresas e consumidores, na medida em que, os comportamentos de ambos, na forma de práticas de marketing e comportamento de consumo, retroalimentam-se mutuamente, como preconiza a Teoria da Firma de Marketing (TFM) (G. R. Foxall, 2020). De acordo a TFM o papel da empresa é programar e arranjar contingências, por meio das ações de marketing, que sinalizem benefícios e aumentem a probabilidade de que os consumidores se aproximem (comprem, consumam, relatem experiências positivas etc.) dos produtos e serviços ofertados. O comportamento do consumidor, por sua vez, é explicado em função do histórico de aprendizagem do indivíduo em interação com seu cenário de consumo, em conformidade com o *Behavioral Perspective Model (BPM)* (Doong et al., 2011; G. Foxall, 2015) de acordo com o ilustrado na Figura 1. A história de aprendizagem está associada aos efeitos das contingências experimentadas previamente pelo consumidor (G. R. Foxall, 1992), a partir dos quais os elementos físicos, sociais, temporais ou verbais presentes no cenário de consumo – alguns deles fruto das ações de marketing das empresas – induzem ou inibem o comportamento, a partir da sinalização de suas prováveis consequências (G. Foxall, 2015). Essas consequências podem ser reforçadoras ou punitivas (quando tornam mais ou menos provável a ocorrência do comportamento em situações similares), e de caráter informativo (simbólicas ou socialmente mediadas) e/ou utilitário (derivadas do valor de uso) (G. Foxall, 2015; G. R. Foxall, 1998). Ainda, o escopo do cenário pode se apresentar como relativamente aberto ou fechado, representado por um continuum que oscila entre maior ou menor nível de restrição às alternativas de comportamento disponíveis (G. R. Foxall & James, 2001). Alterar o cenário de consumo por meio da programação de contingências de reforço que favoreçam a aproximação do consumidor é, portanto, escopo das atividades de marketing.

**Figura 1 - Behavioral Perspective Model (BPM)**



(G. R. Foxall et al., 2006)

Para programar contingências reforçadoras, as empresas precisam dispor de informações acerca da história de aprendizagem dos consumidores, a fim de detectar que elementos do cenário de consumo precisam ser programados. Atividades de inteligência de marketing são fundamentais para esse propósito (G. R. Foxall, 2020). No âmbito da transformação digital (Vial, 2019), o uso de ferramentas de inteligência artificial se apresenta como uma tendência crescente que vem transformando as estratégias de marketing, permitindo a personalização da oferta de produtos e serviços com base em informações sobre o histórico do comportamento do consumidor (Davenport et al., 2011; Fiorini, 2018). Com o aumento da capacidade das empresas de armazenar, integrar e analisar grandes volumes de dados (Venkatram & Mary, 2017), torna-se possível identificar as contingências de consumo às quais os consumidores responderam favoravelmente (contingências reforçadoras, cf. Skinner, 1985) e, a partir desse conhecimento, adotar estratégias como a personalização de conteúdo.

Estratégias de personalização de conteúdo baseadas em análise de dados têm sido utilizadas em diversas áreas como educação (Mart, 2018), reabilitação em saúde (Caggianese et al., 2019; Chatti & Muslim, 2021) e também na área de marketing (Anshari et al., 2019). A personalização online é um processo que identifica padrões e características de navegação, analisa as preferências de usuários similares e fornece conteúdos mais adequados ao consumidor (Lavie et al., 2010). A personalização pode ocorrer também com base na coleta de informação pessoal dos usuários proveniente de fontes diversas, como por exemplo, interesses, preferências e localização geográfica, para melhorar a relevância do conteúdo ofertado (Lopes et al., 2016).

Em uma interpretação analítico-comportamental, pode-se dizer que a oferta de produtos e serviços personalizados é uma estratégia em que se programa o cenário de consumo com base em eventos que sinalizem reforço para o comportamento do consumidor, a partir do conhecimento acerca de sua história de aprendizagem. Nessa perspectiva, a personalização tornaria mais provável a ocorrência de reações como comprar ou usar o serviço novamente ou de apresentar relatos positivos sobre o serviço, como avaliar positivamente a experiência de consumo e relatar intenção compra, por exemplo – todos entendidos como comportamentos de aproximação do consumidor à marca ou empresa. Dados de pesquisa realizada pela Evergage corroboram essa interpretação, ao mostrar que empresas que utilizaram personalização observaram as seguintes mudanças em suas métricas: (a) aumento da conversão (em 65%), (b) aumento do engajamento do

visitante (em 62%) (c) melhora da experiência do usuário (em 61%) e (d) aumento na geração de novos clientes (Freitag, 2016) . Assim a estratégia de personalização aumenta a identificação com a marca e sua aceitação, maximizando oportunidades futuras (TAM; SHUK, 2006), ou seja, aumentando a probabilidade de comportamentos de aproximação à marca.

Mas apesar dos benefícios da personalização de conteúdo, existem situações em que a personalização pode trazer impactos negativos, como: (a) repetição exagerada (causando sensação de exaustão do cliente com a marca), (b) mal direcionamento das publicações (resultando na desconfiança da competência e integridade da empresa) e (c) invasão de privacidade do consumidor por parte das empresas, gerando o sentimento de estar sendo observado e rastreado (Freitag, 2016). Assim, nota-se que a estratégia de personalização pode também envolver a programação de contingências aversivas para o consumidor, o que acarretaria em comportamentos de fuga ou esquiva (Catania, 1999), indesejados pelas empresas.

Em serviços OTT de vídeos, uma forma de programar a personalização é por meio algoritmos que selecionam os vídeos para o portfólio apresentado ao consumidor, com base nas preferências passadas e/ou declaradas, em contraposição a uma oferta aleatória ou a uma oferta programada com base em popularidade (vídeos mais acessados pelo público em geral) por exemplo. A seguir, apresenta-se o método adotado para comparar os efeitos dessas três estratégias sobre métricas de avaliação da experiência e intenção de compra do consumidor.

#### 4. METODOLOGIA

A pesquisa foi de caráter quantitativo (Provdanov & Freitas, 2013) com delineamento experimental, a fim de observar a ocorrência de relações de causa e efeito entre as variáveis dependentes e independentes (Cozby, 2003). Avaliaram-se os efeitos da personalização do portfólio de filmes ofertado sobre métricas de avaliação da experiência do usuário e relato de intenção de compra, em comparação com efeitos da oferta de um portfólio aleatório e um portfólio baseado em popularidade

##### 3.1 Instrumento de pesquisa

Para a realização do experimento, foi criado um site simulando uma plataforma OTT de transmissão de vídeos (protótipo disponível no endereço <https://goofy-cray-ebc15e.netlify.com/#/>.) Para o desenvolvimento da plataforma foi utilizada a *Application Programming Interface* (API) do TMDb visando obter informações referente aos filmes (foto, descrição, ano de lançamento, nome, gênero e vendas de bilheteria).

Os participantes receberam um questionário eletrônico em que preencheram as informações demográficas, assim como algumas preferências cinematográficas (preferência por filmes recentes ou antigos, os três gêneros de filmes favoritos e os dois gêneros de que menos gostavam). Na sequência aparecia uma breve explicação de como funcionaria o experimento, e o indivíduo era exposto a três plataformas de filmes, configuradas com diferentes portfólios de filmes (condições experimentais): a) Plataforma 1 (portfólio aleatório), denominada Filmex, com disposição randômica dos filmes; b)

Plataforma 2 (baseada em popularidade), denominada Filmix, em que apareciam dentro do carrossel de filmes e em ordem decrescente, as películas mais assistidas pelo público em geral (não participantes do experimento); e c) Plataforma 3 (portfólio personalizado), denominada Filmux, com oferta de filmes 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 à ordem de escolha descrita na primeira parte do experimento (os gêneros preferidos informados pelos usuários foram dispostos no topo e os gêneros menos preferidos na parte inferior). Além disso, os dois gêneros apontados como menos favoritos foram excluídos dessa aba.

### 3.2 Variáveis

A variável independente (VI) do estudo foi o tipo de portfólio apresentado ao participante, contendo três variações: (a) Portfólio aleatório, (b) Portfólio baseado em popularidade (filmes organizados de acordo com o ranqueamento geral de bilheterias) e (c) Portfólio personalizado (filmes organizados com base em informações sobre gostos pessoais). A variável dependente (VD) foi uma métrica de avaliação da experiência do usuário, com notas de 1 a 5 atribuídas pelos participantes a cada uma das três plataformas. Coletou-se, também, relatos de intenção de compra (respostas à pergunta "supondo que você possui dinheiro para assinar qualquer uma das três plataformas e que elas custam o mesmo preço, qual delas você assinaria?"). Por fim, as variáveis de controle (VC) foram: (a) dados demográficos (idade, gênero, renda e escolaridade) e (b) frequência de uso nas plataformas Youtube e Netflix, separados em *heavy users* ( $\geq 5$ h semanais) e *light users* ( $< 5$ h semanais).

### 3.3 Participantes

A pesquisa contou com 452 respondentes, ou excluir as respostas duplicadas resultou-se em 421 respostas válidas, apresentando perfis bem diversos, com idades entre 18-83 anos, com gênero predominantemente feminino (56,5%; com 42,28% masculino e 1,66% de outros gêneros). Prevaleram jovens de 21 a 23 anos (45,8%; 26-29 anos = 9.5%; 30-40 anos =7.83%), com nível superior incompleto (61%), predominantemente das classes A (42.51%) e B (18.28%). Em relação ao perfil de uso das plataformas Youtube e Netflix, constata-se que a maioria utilizava Youtube há mais de cinco anos (89,7%) e Netflix há três anos (23,6%) ou mais anos (60,2%). Em ambas as plataformas de *streaming*, observou-se também que a maioria das pessoas eram *light users* (Youtube: 67,9%; Netflix: 63,18%).

### 3.4 Procedimentos de coleta e análise dos dados

Após a visualização de cada plataforma, os usuários as avaliaram com notas de 1 a 5 (avaliação da experiência do usuário, correspondente à variável dependente do estudo).

No final do experimento, os usuários responderam novamente as perguntas sobre avaliação das três plataformas, para que pudessem reavaliar suas notas após a visualização de todas elas. As notas finais foram utilizadas como variáveis dependentes no experimento. Os participantes informaram, ainda, qual das três plataformas assinariam (intenção de compra).

Os dados foram colhidos e armazenados em um DataSet na plataforma *Airtable* e o processo de análise de dados foi realizado nas plataformas SPSS, R Studio e Excel. Para análise dos dados adotaram-se procedimentos de estatística não paramétrica, dada a natureza categórica da VD Intenção de Compra e a distribuição não normal da VD Avaliação da Experiência do Usuário ( $W_{Nota1} = 0,90, p < 0,01$ ;  $W_{Nota2} = 0,87, p < 0,01$ ;  $X^2_{Nota3} = 0,85, p < 0,01$ ).

## 5. RESULTADOS E DISCUSSÃO

Na Tabela 1 encontra-se os resultados descritivos obtidos para cada variável dependente: (a) Avaliação da experiência do usuário: notas de 1 a 5 para cada plataforma (Tabela 1) e (b) Intenção de compra: plataforma que o usuário assinará. A plataforma 1 (Oferta aleatória), teve suas notas concentradas entre 3 (33%) e 4 (34%). Na plataforma 2 (Oferta baseada em Popularidade) a nota 4 (40,4%) foi a mais votada, e as notas 3 (25,4%) e 5 (24,9%) aparecem com distribuição equilibrada em seguida. A plataforma 3 (Oferta Personalizada) apresentou um comportamento diferente. Nas plataformas 1 e 2, a nota 3 teve mais de 30% dos votos, enquanto na terceira plataforma teve apenas 22,8% do total. Além disso, as notas 4 (38,7%) e 5 (32,3%) foram as mais votadas. Apesar de as médias das três plataformas terem sido próximas, a nota 5 teve uma ocorrência bem maior nas plataformas 3 e 2, respectivamente.

Quanto à intenção de compra, observou-se que a Plataforma 3 foi a preferida por quase metade dos participantes ( $n=208$ ; 49,4%), seguida da Plataforma 2 ( $n=127$ ; 30,2%) e da 1 ( $n=86$ ; 20,4%).

**Tabela 1** - Análises descritivas

	<b>Plataforma 1</b> <b>Oferta Aleatória</b>	<b>Plataforma 2</b> <b>Oferta Popularidade</b>	<b>Plataforma 3</b> <b>Oferta Personalizada</b>
<b>Nota 1</b>	16 (3.8%)	7 (1.7%)	3 (0.7%)
<b>Nota 2</b>	43 (10.2%)	32 (7.6%)	23 (5.5%)
<b>Nota 3</b>	139 (33%)	107 (25.4%)	96 (22.8%)
<b>Nota 4</b>	143 (34%)	170 (40.4%)	163 (38.7%)
<b>Nota 5</b>	80 (19%)	105 (24.9%)	136 (32.3%)
<b>Nota Média</b>	3.54	3.79	3.96
<b>Desvio-padrão</b>	1.02	0.95	0.91
<b>Intenção de Compra</b>	86 (20.4%)	127 (30.2%)	208 (49.4%)

### 5.1 Avaliação dos efeitos da personalização

Inicialmente, para verificar se a intenção de compra estaria associada a efeitos de variáveis sociodemográficas e de comportamento de uso, realizou-se um teste chi quadrado para independência ( $\alpha=0,05$ ) entre relatos de intenção de compra e essas variáveis. Todos os perfis apresentaram distribuições similares de preferências entre as plataformas, não havendo, portanto, associação significativa da intenção de compra com as características demográficas e comportamento de uso das plataformas (*heavy ou light users*) ( $X^2$ escolaridade(8)=11,82;  $p=0,16$ ;  $X^2$ gênero(8)=12,63;  $p=0,13$ ;  $X^2$ renda(8)=0,67;  $X^2$ tempoYoutube(14)=8,59;  $p=0,86$ ;  $X^2$ tempoNetflix(14)=3,65).

Como apresentado no método, adotaram-se duas formas de avaliação dos efeitos da oferta personalizada: a) comparação entre as médias das notas atribuídas às três plataformas, independentemente da plataforma apontada como preferida na questão de intenção de compra (variável dependente: avaliação da experiência do usuário) e b) comparação entre as médias das notas atribuídas às três plataformas, dentre estratos amostrais separados por plataforma preferida (conforme intenção de compra).

### 5.1.1 Comparação entre métricas de avaliação da experiência do usuário (notas) das três plataformas

Para comparar a influência dos portfólios (notas atribuídas às três plataformas simuladas no experimento) realizou-se uma teste de Friedman (que testa efeitos de mais de duas condições experimentais quando os mesmos participantes são expostos a todas elas – como foi o caso neste experimento, em que cada participante avaliou as três plataformas). O teste para verificar se as médias das notas atribuídas às plataformas diferiam entre si apoiou evidências de que ao menos uma das médias apresentava valores diferentes das demais ( $X^2(2)=59,269$ ;  $p<0,01$ ). Partiu-se então para o teste *post hoc* não paramétrico de Wilcoxon pareado, com correção de Bonferroni [ $\alpha=0,05/3$ ; ou seja  $\alpha=0,0167$  (Field, 2011)], para identificar diferenças entre médias de notas das plataformas par a par (Tabela 2).

**Tabela 2:** Teste de Wilcoxon pareado: valores de significância observados na comparação de notas médias, par a par

Notas	Plataforma 1 x 2	Plataforma 2 x 3	Plataforma 1 x 3
Valor <i>p</i>	0,001*	0,009*	0,001*

Nota1: H0: Média 1 = Média 2 = Média 3; H1: Média 1 < Média 2; H2: Média 2 < Média 3; H3: Média 1 < Média 3

Para todas as comparações entre pares rejeitaram-se as hipótese nulas de que as médias das avaliações não seriam diferentes. Assim, observa-se que as médias das notas atribuídas às Plataformas 1, 2 e 3 podem ser ranqueadas em ordem crescente, o que, em conjunto com a intenção de compra predominante da Plataforma 3, demonstrou preferência dos consumidores pelos portfólios personalizados, seguidos daqueles baseados em popularidade (Plataforma 2).

### 5.1.2 Métricas de avaliação da experiência do usuário (notas das plataformas) por grupos de intenção de compra

Realizaram-se três rodadas do teste de Friedman, uma com cada estrato da amostra propensa a escolher aquela plataforma (Estratos 1, 2 e 3, correspondentes à escolha das Plataformas 1, 2 e 3), para verificar se as médias das notas atribuídas às três plataformas (na questão de avaliação da experiência do usuário) seriam significativamente diferentes entre si. Para os três estratos, os resultados (Tabela 3) sugerem que as notas variaram significativamente entre as plataformas com diferentes ofertas de portfólio de filmes.

**Tabela 3:** Teste de Friedman: Comparação de médias das plataformas.

Notas	Chi quadrado	p-valor
Plataforma 1	166,75	<0,001
Plataforma 2	254,7	<0,001
Plataforma 3	376,01	<0,001

Nota.:  $H_0$ : a média das três notas é igual;  $H_1$ : Pelo menos uma das notas é diferente;  $\alpha=0,05$ ;  $gl=2$ .

Para um diagnóstico acerca das diferenças entre as avaliações atribuídas às plataformas, para cada estrato de intenção de compra realizaram-se testes *post hoc* de Wilcoxon pareados (Tabela 4) para comparar as médias par a par.

**Tabela 4:** Testes de Wilcoxon pareado para os três estratos: significância (unilateral)

	Nota 2 x 1	Nota 3 x 2	Nota 3 x 1
<b>Estrato 1</b>	1	0,8426	1
<b>Estrato 2</b>	0.001*	1	0.006*
<b>Estrato 3</b>	0.001*	0.001*	0.001*

Nota.:  $H_0$ : Média 1 = Média 2 = Média 3;  $H_1$ : Média 1 < Média 2;  $H_2$ : Média 2 < Média 3;  $H_3$ : Média 1 < Média 3;  $\alpha = 0,0167$  (com correção de Bonferroni para três testes); n (Estrato 2) = 86; n (Estrato 3) = 127.

Verificou-se que apenas no Estrato 3 (Plataforma 3, personalizada) os usuários atribuíram diferentes notas às três plataformas avaliadas (Média 3 > Média 2 > Média 1). No estrato de participantes que assinariam a Plataforma 2 (baseada em popularidade), a média das notas atribuídas às Plataformas 2 e 3 não apresentaram diferenças significativas entre si, e foram ambas significativamente maiores do que a média da Plataforma 1. Esse resultado se alinha com o perfil de preferência do estrato, que apontou intenção de compra da Plataforma 2 e a avaliou, embora em empate com a Plataforma 3, com as melhores notas.

Observa-se que a Plataforma 2 foi programada para ofertar filmes com alta popularidade, o que sinaliza majoritariamente reforço informativo, com a possibilidade de reconhecimento ou interação social por meio do acesso à cultura cinematográfica reconhecida socialmente. Esse resultado sugere que, para um determinado segmento de consumidores, a utilização de plataformas de *streaming* pode ter a função de favorecer a

inserção ou interação social, sinalizando reforços de caráter informativo em maior magnitude do que reforços utilitários

O teste apresentado na tabela 4 foi realizado com o intuito de comparar os achados com os resultados encontrados na pesquisa de Kim (2017), no qual realizou um experimento na China e na Korea em que os participantes davam notas aos atributos selecionados pelo pesquisador, sendo um desses atributos o próprio sistema de recomendação, que variava entre a) recomendação popular de conteúdo e b) recomendação personalizada de conteúdo. Os resultados encontrados evidenciam que na opinião do público ambos os sistemas a e b tiveram uma boa performance quando perguntado a importância daquele atributo para aumentar as probabilidades de compra, sendo na Coreia o atributo mais relevante para decisão dos consumidores e na China o segundo atributo de maior importância, só perdendo para a resolução da imagem. Portanto os resultados encontrados nessa pesquisa corroboram com os encontrados em 2017 por Kim.

Os reforços utilitários podem ter sido prevalentes, neste experimento, no portfólio personalizado, programado a partir das preferências por estilos e gêneros dos filmes. Os relatos de preferências, realizados pelos consumidores quando das respostas iniciais ao questionário, forneceram pistas sobre contingências reforçadoras associadas a determinados gêneros de filmes que o consumidor assistiu no passado, permitindo a programação de um portfólio de filmes que sinalizasse essas mesmas consequências (derivadas diretamente do valor funcional desses filmes para o consumidor) por meio do menu de películas.

O experimento mostrou que apesar de a Plataforma 3, personalizada, ter apresentado maior efetividade junto à amostra como um todo, nem sempre a programação de portfólios personalizados se apresenta como a opção mais efetiva. Assim, os resultados apontaram para a existência de segmentos de consumidores que provavelmente maximizam utilidade a partir de diferentes níveis de reforços utilitários e informativo oferecidos pelas plataformas, como já foi observado por Oliveira-Castro, Cavalcanti e Foxall (2015) em pesquisa com bens de consumo de compra rotineira.

Os resultados mostraram também que, para o grupo de participantes do Estrato 1, a programação de reforços via configuração de portfólios personalizados ou populares não surtiu efeito significativo, indicando a importância de que estudos experimentais sejam conduzidos antes da ampla adoção de algoritmos para a programação de portfólios de filmes. Para o grupo do Estrato 1, o reforço pode estar mais associado à variabilidade comportamental (Neuringer, 2002), o que pode ser favorecido por uma apresentação aleatória de alternativas de filmes, que permita surpresa e novidade. Padrões de comportamento de variabilidade em consumo já foram reportados na literatura de escolha de marcas (Ehrenberg et al., 2004). Apesar de escolherem a Plataforma aleatória, esses consumidores pareceram ter avaliado de forma similar as três plataformas, o que no entanto permanece inconclusivo em função dos resultados contraditórios da Anova de Friedman e do Teste de Wilcoxon pareado.

## 6. CONCLUSÃO

O presente estudo comparou o efeito da exposição a diferentes portfólios de filmes sobre métricas de avaliação da experiência dos usuários, a fim de avaliar o efeito de portfólio personalizado em comparação com portfólio baseado em popularidade e portfólio com oferta aleatória de filmes. Nas análises realizadas com dados da amostra de participantes como um todo, foi verificada eficácia superior da plataforma que ofertou portfólio personalizado, seguida da plataforma com portfólio baseado em popularidade, em detrimento da plataforma com oferta aleatória de filmes. A eficácia foi avaliada por meio de medidas de avaliação da experiência dos usuários, combinada com a indicação da intenção de compra (assinatura) das plataformas.

Embora a Plataforma Personalizada tenha obtido maiores médias de avaliações, maior intenção de compra, e maiores avaliações do que as demais plataformas entre os participantes que as assinariam, observou-se a formação de diferentes segmentos de consumidores de serviços OTTs de vídeos, com preferências por portfólios de filmes que sinalizam diferentes padrões de reforço: variabilidade, maximização de reforço informativo e maximização de reforço utilitário.

Em uma perspectiva analítico-comportamental, considera-se que o termo personalização, entendido como a adaptação da oferta de marketing à história de aprendizagem do consumidor, poderia ser usado para se referir às três contingências de reforço comparadas, já que diferentes histórias de aprendizagem podem produzir preferências (entendidas como disposições, cf. Ryle, 2009) por tipos específicos de abordagem. Essa constatação aponta para a necessidade de uma revisão conceitual do termo personalização, como vem sendo usado na literatura.

Apesar de os dados apresentados apontarem para uma tendência de comportamento de consumo, a pesquisa apresenta algumas limitações: baixa quantidade de dados dos filmes e a implementação de um algoritmo com poucas informações dos usuários. Grandes plataformas de streaming podem utilizar maior quantidade de parâmetros e fazer análises mais assertivas quanto aos perfis e algoritmos.

Além disso, a Plataforma 3 (personalizada) contou com um informe que mostrava aos participantes que o conteúdo era personalizado, com a frase “Recomendados para você”, a qual não foi exposta aos participantes das demais plataformas. Essa informação pode ter atuado como variável interveniente. Em estudos anteriores verificaram efeito significativo da personalização percebida (versus não percebida) sobre variável de intenção de adoção de tecnologia de personalização (Komiak & Benbasat, 2006). Portanto, sugere-se que em futuros estudos sejam testados efeitos desse tipo mensagem.

Como agenda, sugere-se ainda a implementação da análise de consumo em plataformas reais, além da investigação dos efeitos da personalização de portfólios de filmes ou outros produtos com base no histórico de comportamento dos usuários, e não apenas com base em relatos de preferências.

O estudo apresenta contribuições teóricas e metodológicas, dado que o experimento simula o efeito de práticas de marketing sobre o comportamento do consumidor, produzindo métricas capazes de retroalimentar a atuação mercadológica, como previsto na Teoria da Firma de Marketing. Contribui, ainda, no que diz respeito a mais uma demonstração de efeitos diferenciais do reforço informativo e utilitário, categorias analíticas propostas no *Behavioral Perspective Model*. O resultado também chama a

atenção de gerentes de marketing para a importância não só da personalização, quanto da dimensão social da oferta programada para os consumidores e da preferência por variabilidade. Destaca-se, por fim, também uma contribuição de caráter metodológico, dado que o estudo demonstra e testa o uso de algoritmos de inteligência artificial para a pesquisa científica na área de marketing e análise do comportamento do consumidor.

## REFERENCIAL

- Anshari, M., Almunawar, M. N., Lim, S. A., & Al-Mudimigh, A. (2019). Customer relationship management and big data enabled: Personalization & customization of services. *Applied Computing and Informatics*, 15(2), 94–101. <https://doi.org/10.1016/j.aci.2018.05.004>
- Brasscom. (2019). *Relatório Setorial de TIC 2019*. <https://brasscom.org.br/relatorio-setorial-de-tic-2019>
- Caggianese, G., Cuomo, S., Esposito, M., Franceschini, M., Gallo, L., Infarinato, F., Minutolo, A., Piccialli, F., & Romano, P. (2019). Serious Games and In-Cloud Data Analytics for the Virtualization and Personalization of Rehabilitation Treatments. *IEEE Transactions on Industrial Informatics*, 15(1), 517–526. <https://doi.org/10.1109/TII.2018.2856097>
- Catania, A. C. (1999). *Aprendizagem e comportamento. Aprendizagem: comportamento, linguagem e cognição*.
- Chatti, M. A., & Muslim, A. (2021). International Review of Research in Open and Distributed Learning The PERLA Framework: Blending Personalization and Learning Analytics The PERLA Framework: Blending Personalization and Learning Analytics The PERLA Framework: Blending Personalization and L. *Erudit.Org*. <https://doi.org/10.7202/1057982ar>
- Cozby, P. C. (2003). *Métodos de Pesquisa Em Ciências Do Comportamento*.
- Davenport, T. H., D'Amico, L. D., & Lucker, J. (2011). Know what your customers want before they do. *Harvard Business Review*, 89(12).
- Doong, H. Sen, Wang, H. C., & Foxall, G. R. (2011). An investigation of consumers' webstore shopping: A view of click-and-mortar company. *International Journal of Information Management*, 31(3), 210–216. <https://doi.org/10.1016/j.ijinfomgt.2010.06.006>
- Ehrenberg, A. S. C., Uncles, M. D., & Goodhardt, G. J. (2004). Understanding brand performance measures: Using Dirichlet benchmarks. *Journal of Business Research*, 57(12 SPEC.ISS.), 1307–1325. <https://doi.org/10.1016/j.jbusres.2002.11.001>
- Erevelles, S., Fukawa, N., & Swayne, L. (2016). Big Data consumer analytics and the transformation of marketing. *Journal of Business Research*, 69(2), 897–904. <https://doi.org/10.1016/j.jbusres.2015.07.001>
- Field, A. (2011). Descobrimos a estatística usando o SPSS. In *Aletheia* (Issues 35–36).
- Fiorini, L. (2018). How artificial intelligence will change the future of bullion production. *42nd International Precious Metals Institute Annual Conference, IPMI 2018*, 60–69.
- Foxall, G. (2015). *The Routledge Companion to Consumer Behavior Analysis*. The

- Routledge Companion to Consumer Behavior Analysis, June.*  
<https://doi.org/10.4324/9781315850696>
- Foxall, G. R. (1992). The behavioral perspective model of purchase and consumption: From consumer theory to marketing practice. *Journal of the Academy of Marketing Science*, 20(2), 189–198. <https://doi.org/10.1007/BF02723458>
- Foxall, G. R. (1998). Radical behaviorist interpretation: Generating and evaluating an account of consumer behavior. *Behavior Analyst*, 21(2), 321–354. <https://doi.org/10.1007/BF03391971>
- Foxall, G. R. (2020). The theory of the marketing firm. *Managerial and Decision Economics*, 41(2), 164–184. <https://doi.org/10.1002/mde.3047>
- Foxall, G. R., & James, V. K. (2001). The Behavioral Basis of Consumer Choice: A Preliminary Analysis. *European Journal of Behavior Analysis*, 2(2), 209–220. <https://doi.org/10.1080/15021149.2001.11434195>
- Foxall, G. R., Oliveira-Castro, J. M., James, V. K., Yani-de-Soriano, M. M., & Sigurdsson, V. (2006). Consumer Behavior Analysis and Social Marketing: The Case of Environmental Conservation. *Behavior and Social Issues*, 15(1), 101–125. <https://doi.org/10.5210/bsi.v15i1.338>
- Freitag, E. A. (2016). *E QUANDO A PERSONALIZAÇÃO NÃO DÁ CERTO? Fatores que influenciam negativamente a percepção do consumidor em relação à personalização online.*
- Kagermann, H., Wahlster, W., & Helbig, J. (2013). Securing the future of German manufacturing industry: Recommendations for implementing the strategic initiative INDUSTRIE 4.0. *Final Report of the Industrie 4.0 Working Group, April*, 1–84.
- Kim, M. S., Kim, E., Hwang, S. Y., Kim, J., & Kim, S. (2017). Willingness to pay for over-the-top services in China and Korea. *Telecommunications Policy*, 41(3), 197–207. <https://doi.org/10.1016/j.telpol.2016.12.011>
- Komiak, S. Y. X., & Benbasat, I. (2006). <sup>^^ Uldl I C- ^ I I \ f</sup> Research Article The Effects of Personalization and Familiarity on Trust and Adoption of Recommendation Agents. *MIS Quarterly*, 30(4), 941–960.
- Lavie, T., Sela, M., Oppenheim, I., Inbar, O., & Meyer, J. (2010). User attitudes towards news content personalization. *International Journal of Human Computer Studies*, 68(8), 483–495. <https://doi.org/10.1016/j.ijhcs.2009.09.011>
- Lopes, C., Cabral, B., & Bernardino, J. (2016). Personalization using Big Data Analytics Platforms. *ACM International Conference Proceeding Series, 20-22-July*, 131–132. <https://doi.org/10.1145/2948992.2949000>
- Mart, A. S. (2018). Attentive Collaborative Filtering : Multimedia Recommendation with Item- and Component-Level Attention Paula Navarrete Campos Outline. *Sigir 17*, 335–344.
- Panorama Mobile Time/Opinion Box. (2020). *Uso de Apps no Brasil - Dezembro de 2020*. 20.
- Price Waterhouse Coopers. (2018). Trending now : convergence , connections and trust. PwC.
- Provdanov, C. C., & Freitas, E. C. De. (2013). Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico. In *Novo Hamburgo*:

- Feevale*. <https://doi.org/10.1017/CBO9781107415324.004>
- Ryle, G. (2009). The Concept of Mind (first published 1949). In *Library, London*.
- Skinner, B. F. (1985). Cognitive science and behaviourism. *British Journal of Psychology*, 76(3), 291–301. <https://doi.org/10.1111/j.2044-8295.1985.tb01953.x>
- Venkatram, K., & Mary, A. G. (2017). Review on big data & analytics - Concepts, philosophy, process and applications. *Cybernetics and Information Technologies*, 17(2), 3–27. <https://doi.org/10.1515/cait-2017-0013>
- Vial, G. (2019). Understanding digital transformation: A review and a research agenda. *Journal of Strategic Information Systems*, 28(2), 118–144. <https://doi.org/10.1016/j.jsis.2019.01.003>