



**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE ECONOMIA, ADMINISTRAÇÃO CONTABILIDADE E GESTÃO DE**  
**POLÍTICAS PÚBLICAS (FACE)**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO**  
**DOUTORADO EM ADMINISTRAÇÃO**

**DESEMPENHO DE MARCA E COMPORTAMENTO DE USO DE MARCAS DE**  
**APLICATIVOS: INFLUÊNCIA DE VARIÁVEIS SITUACIONAIS**

**Gislayne da Silva Goulart**

**Orientador: Prof. Dr. Rafael Barreiros Porto**

**Tese de Doutorado**

**Brasília/DF**  
**2022**

**UNIVERSIDADE DE BRASÍLIA**  
**FACULDADE DE ECONOMIA, ADMINISTRAÇÃO CONTABILIDADE E GESTÃO DE**  
**POLÍTICAS PÚBLICAS (FACE)**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO**  
**DOUTORADO EM ADMINISTRAÇÃO**

**DESEMPENHO DE MARCA E COMPORTAMENTO DE USO DE MARCAS DE**  
**APLICATIVOS: INFLUÊNCIA DE VARIÁVEIS SITUACIONAIS**

**Gislayne da Silva Goulart**

Tese submetida ao Programa de Pós-Graduação em Administração da Universidade de Brasília, como requisito parcial para obtenção do título de Doutor em Administração.

Linha de pesquisa: Estratégia, Marketing e Inovação

Orientador: Professor Doutor Rafael Barreiros Porto

**Brasília/DF, 01 de junho de 2022**

**DESEMPENHO DE MARCA E COMPORTAMENTO DE USO DE MARCAS DE  
APLICATIVOS: INFLUÊNCIA DE VARIÁVEIS SITUACIONAIS**

Tese apresentada em 01 de junho de 2022, como requisito parcial à obtenção do grau de Doutor em Administração. Aprovada pela seguinte Comissão Examinadora:

---

**Professor Doutor Rafael Barreiros Porto**

Presidente

Programa de Pós-Graduação em Administração (PPGA)  
Universidade de Brasília (UnB)

---

**Professor Doutor Jorge Mendes Oliveira Castro**

Membro interno – Universidade de Brasília (UnB)

---

**Professor Doutor Gabriel Sperandio Milan**

Membro externo – Universidade do Vale do Rio dos Sinos (UNISINOS)

---

**Professor Doutor Ricardo Limongi França Coelho**

Membro externo – Universidade Federal de Goiás (PPGA/UFG)

---

**Professora Doutora Eluiza Alberto de Moraes Watanabe**

Membro interno suplente – Universidade de Brasília (UnB)

## **Agradecimentos**

A Deus por sempre iluminar os meus passos e nunca me desamparar.

Ao meu pai Antonio Brito Goulart e à minha mãe Fátima Maria P. da Silva Goulart (*in memoriam*) pelo amor incondicional e inesgotável meu profundo reconhecimento a todo o esforço e dedicação de vocês a mim e aos meus estudos. Obrigado por sonharem comigo este sonho e por todo o suporte que me possibilitou chegar até aqui.

Ao meu irmão Cleyton da Silva Goulart por todo o amor, carinho e também pela compreensão nas ausências.

Ao professor Dr. Rafael Porto, meu orientador, pelos valiosos ensinamentos, direcionamentos, incentivos, oportunidades, disponibilidades e confiança em mim.

À Cristina Goulart e ao Yoannes Geissler por toparem o desafio de desenvolverem e darem todo o suporte técnico do mBehavior App, sem vocês minha coleta de dados teria tomado outro rumo.

À Laisa Fernanda pelo apoio e estar presente em todas as fases de construção do projeto M-Behavior.

Ao Grupo de Pesquisa Experimenta pelas valiosas contribuições ao estudo.

Às professoras Dr<sup>a</sup>. Eluiza Watanabe e Amalia Pérez e ao professor Dr. Ricardo Limongi pelas importantes considerações e sugestões ao longo do desenvolvimento desta pesquisa.

Aos amigos Newton Miranda Júnior e Mayra Vieira, cada um ao seu modo, pelo apoio em muitos momentos ao longo deste processo.

A todos os meus familiares, amigos e colegas que de alguma forma contribuíram para a realização desse sonho, em especial à minha madrinha Sandra Goulart.

Várias pessoas me ajudaram de tantas maneiras diferentes para a realização deste trabalho e a elas sou muito grata: prof<sup>a</sup> Patrícia, Paulo, Matheus, Doglas, Bruno, Alan, Isaura, Julietty, Milton, Renan, Márcia.

A todas(os) voluntárias(os) que participaram do projeto mBehavior e compartilharam seus dados motivados, principalmente, por interesse altruísta.

A aqueles que de forma direta e indireta contribuíram para a realização desse sonho, mesmo que não citados aqui.

*Floresça onde Deus te plantar!*

## Resumo

Esta tese buscou avançar o entendimento se padrões de desempenho de marcas e de comportamento de compra de marcas também se aplicam/estendem ao desempenho e comportamento no nível do uso efetivo de marcas de aplicativos. Procurou-se responder como as marcas de aplicativos competem e como e quais variáveis situacionais impulsionam o desempenho e o uso de marcas de aplicativos. Neste direcionamento, esta tese teve como objetivo geral estimar padrões de desempenho e uso de marcas de aplicativos e seus antecedentes situacionais. Realizou-se uma triangulação metodológica com aporte nas abordagens de marketing baseado em evidências e de perspectiva comportamental. Estruturalmente, foram desenvolvidos três estudos complementares - dois no nível de desempenho de marcas de aplicativos; um no nível do comportamento efetivo de uso de marcas de aplicativos pelo consumidor, utilizando dados desagregados dos estudos 1 e 2. O Estudo 1 examinou se as marcas de aplicativos seguem padrões de desempenho de marcas bem estabelecidos na literatura em contexto de compra, ao que tangencia o tamanho da marca, lealdade comportamental e compartilhamento da base de consumidores. Com auxílio do modelo NBD-Dirichlet, análises foram conduzidas com dados de um painel de consumidores, composto por quase 350 mil registros de acessos padronizados a 237 marcas de aplicativos de quatro categorias durante 30 dias. Os resultados revelaram que (i) o uso de repertório de marcas pelos consumidores é previsível pelo modelo, (ii) as marcas de aplicativos têm níveis esperados de lealdade para seu tamanho e compartilham seus consumidores com outras marcas intra-categoria de acordo com as suas penetrações de uso e, sob certas condições, (iii) os consumidores consomem os aplicativos intra-categoria como produtos complementares. O Estudo 2 analisou o impacto da força da marca no desempenho de marcas de aplicativos nos estágios de adoção e uso efetivo pelo consumidor, testando moderação da categoria do aplicativo. Foram elaborados dois painéis de dados de consumidores enriquecidos com metadados disponíveis em uma loja de aplicativos para a proposição de uma medida de força da marca. O primeiro testou o impacto da força da marca no desempenho (penetração por aquisição) de 773 marcas de aplicativos no estágio de adoção e o segundo testou sobre o desempenho (penetração, *market share* e lealdade) de 237 marcas de aplicativos no estágio de uso efetivo. Análises de regressão quantílica foram realizadas sobre as variáveis de desempenho de marca. Os resultados revelaram que a força da marca tem um impacto positivo e significativo na penetração por aquisição e nas medidas de desempenho de uso efetivo da marca – com destaque para a lealdade. O Estudo 3 analisou a influência de variáveis situacionais sob o controle relativo do consumidor (estímulo temporal e social) e de gestores (estímulos do ambiente virtual) sobre o comportamento efetivo de uso de marcas de aplicativos (frequência de uso e alteração do repertório) pelo consumidor, testando moderação da experiência mobile do consumidor. Um experimento longitudinal em ambiente natural foi conduzido junto a 101 consumidores (N = 3.030 pontos de registros). Os resultados revelaram que tanto variáveis situacionais sob o controle relativo de gestores, com um impacto mais forte sobre a frequência de uso, quanto sob o controle do consumidor, com um impacto mais forte sobre a ocorrência de alteração do repertório, mostraram-se preditoras do uso de marcas de aplicativos. Em conjunto, os três estudos revelaram que os padrões encontrados no contexto de compra da marca se estendem ao contexto de uso efetivo de marcas de aplicativos. Esta tese contribuiu, assim, para a extensão e avanço das teorias sobre padrões de desempenho e comportamento de compra de marcas para o nível do comportamento de uso efetivo de marcas, lançando luz sob a robustez das abordagens de marketing baseado em evidência e de perspectiva comportamental para avançar o conhecimento no campo em ascensão do mobile marketing.

**Palavras-chaves:** Comportamento do consumidor. Repertório de marcas. Gestão de marcas. mBehavior App.

## Abstract

This thesis sought to advance the understanding of whether patterns of brand performance and brand buying behavior also apply/extend to performance and behavior at the level of branded app usage. We sought to answer how branded apps compete and how and which situational variables drive the performance and use of branded apps. In this direction, this thesis had as general objective to estimate performance and use patterns of branded app and its situational antecedents. A methodological triangulation was carried out with a contribution to the evidence-based marketing approach and the behavioral perspective approach. Structurally, three complementary studies were developed - two studies at the branded app performance level; a study at the consumer's branded app usage behavior level, using disaggregated data from studies 1 and 2. Study 1 examined whether branded apps follow well-established brand performance standards in the literature in the purchase context, as far as the brand size, behavioral loyalty, and consumer base share. With the help of the NBD-Dirichlet model, analyzes were conducted with data from a panel of consumers, composed of nearly 350,000 records of standardized access to 237 branded apps in four categories over 30 days. The results revealed that (i) consumers' use of the brand repertoire is predictable by the model, (ii) branded apps have expected loyalty levels for their size and share their consumers with other intra-category brands according to their usage penetrations and, under certain conditions, (iii) consumers consume intra-category apps as complementary products. Study 2 analyzed the impact of brand strength on the performance of app brands in the consumer adoption and usage stages, testing app category moderation. Two consumer data panels enriched with metadata available in an app store were created to propose a measure of brand strength. The first panel tested the impact of brand strength on the performance (acquisition penetration) of 773 branded apps in the consumer adoption stage and the second panel tested the impact of brand strength on the performance (penetration, market share and loyalty) of 237 branded apps in the consumer usage stage. Quantile regression analyzes were performed on brand performance variables. The results revealed that brand strength has a positive and significant impact on acquisition penetration and on performance measures of brand usage stage – especially loyalty. Study 3 analyzed the influence of situational variables under the relative control of the consumer (temporal and social stimulus) and managers (virtual environment stimuli) on the consumer's usage of branded apps (frequency of use and change of repertoire), testing moderation of the consumer's mobile experience. A longitudinal experiment in a natural environment was conducted with 101 consumers (N = 3,030 recording points). Results indicated that both variables under the relative control of managers, with a stronger impact on frequency of use, and those under the relative control of consumers, with a stronger impact on repertoire alteration, were predictors of the use of branded apps. Taken together, the three studies revealed that the patterns found in the context of brand purchase extend to the context of branded app usage. Thus, this thesis contributed to the extension and advancement of theories about patterns of brand performance and brand buying behavior to the level of brand usage behavior, shedding light on the robustness of the evidence-based marketing approach and the behavioral perspective approach to advancing knowledge in the burgeoning field of mobile marketing.

**Keywords:** Consumer behavior. Brand repertoire. Brand management. mBehavior App.

## Lista de Figuras

Figura 1. <i>Visão geral da tese – questões-chave de pesquisa em aberto na literatura</i> .....	20
Figura 2. <i>Instrumento de coleta de dados – mBehavior App</i> .....	33
Figura 3. <i>Descrição das métricas para marcas de aplicativos no estágio de uso efetivo</i> .....	36
Figura 4. <i>Double Jeopardy e Benchmark Dirichlet</i> .....	41
Figura 5. <i>Modelo teórico</i> .....	54
Figura 6. <i>Descrição das variáveis</i> .....	57
Figura 7. <i>Modelos 1, 2 e 4 - Variação das estimativas dos coeficientes da RQ</i> .....	60
Figura 8. <i>Modelo Conceitual</i> .....	79
Figura 9. <i>Grupos, subgrupos e nome de variáveis: suas codificações, designação e análise descritiva</i> .....	81
Figura 10. <i>Predição da frequência de uso de marcas de aplicativos</i> .....	86
Figura 11. <i>Curva ROC de ajuste dos modelos da alteração do repertório</i> .....	88
Figura 12. <i>Apresentação da interface de interação inicial do mBehavior App</i> .....	129
Figura 13. <i>Apresentação do menu do mBehavior App - parte 1</i> .....	130
Figura 14. <i>Apresentação do menu do mBehavior App - parte 2</i> .....	131
Figura 15. <i>Apresentação do menu do mBehavior App - parte 3</i> .....	132
Figura 16. <i>Prints da loja de aplicativos</i> .....	145
Figura 17. <i>Validação das medidas de conhecimento e qualidade percebida de marcas de apps por especialistas</i> .....	147
Figura 18. <i>Estrutura da coleta e tratamento dos dados</i> .....	148
Figura 19. <i>Box-plot do indicador de força da marca por categoria</i> .....	150
Figura 20. <i>Ranking das marcas por categoria</i> .....	152
Figura 21. <i>Acesso médio por janela temporal/dia</i> .....	160
Figura 22. <i>Proporção de acesso por janela temporal/dia</i> .....	161
Figura 23. <i>Análise de Cluster</i> .....	161
Figura 24. <i>Tipologia de configuração de intensidade de acessos aos apps ao longo do dia – Síntese</i> .....	162
Figura 25. <i>Modelo de Análise de Classes Latentes</i> .....	165



Figura 26. <i>Variáveis consideradas para a análise de perfil latente de experiência mobile do consumidor</i> .....	166
Figura 27. <i>Possíveis covariantes do perfil latente</i> .....	168

## Lista de Tabelas

Tabela 1. <i>Visão geral das categorias de aplicativos consideradas neste estudo</i> .....	35
Tabela 2. <i>Medidas de desempenho de mercado</i> .....	39
Tabela 3. <i>Duplicação para marcas de aplicativo da categoria Social</i> .....	43
Tabela 4. <i>Resultados das estimativas e dos ajustes para os modelos de frequência de uso de marca de aplicativos</i> .....	84
Tabela 5. <i>Resultados das estimativas e dos ajustes para os modelos de alteração do repertório de marcas de aplicativos</i> .....	87
Tabela 6. <i>Duplicação para marcas de aplicativo da categoria Comunicação</i> .....	139
Tabela 7. <i>Duplicação para marcas de aplicativo da categoria de Educação</i> .....	140
Tabela 8. <i>Duplicação para marcas de aplicativo da categoria Saúde &amp; Fitness</i> .....	141
Tabela 9. <i>Amostra de aplicativos por categoria</i> .....	148
Tabela 10. <i>As quatro marcas com maior e menor indicador de força da marca por categoria</i> ..	151
Tabela 11. <i>Penetração (por aquisição) - Resultados da Regressão Quantílica dos modelos 1 e 2</i> .....	153
Tabela 12. <i>Penetração de uso - Resultados da Regressão Quantílica. dos modelos 1 e 2</i> .....	153
Tabela 13. <i>Market Share de uso - Resultados da Regressão Quantílica dos modelos 1 e 2</i> .....	154
Tabela 14. <i>Lealdade Comportamental - Resultados da Regressão Quantílica dos modelos 1 e 2</i> .....	154
Tabela 15. <i>Penetração (por aquisição) - Resultados da Regressão de Quantílica com efeito moderador<sup>#</sup></i> .....	155
Tabela 16. <i>Penetração de uso - Resultados da Regressão de Quantílica com efeito moderador<sup>#</sup></i> .....	156
Tabela 17. <i>Market Share de uso - Resultados da Regressão de Quantílica com efeito moderador<sup>#</sup></i> .....	157
Tabela 18. <i>Lealdade Comportamental - Resultados da Regressão de Quantílica com efeito moderador<sup>#</sup></i> .....	158
Tabela 19. <i>Estatísticas de adequação para modelos de uma a seis classes</i> .....	169
Tabela 20. <i>Probabilidade estimada de classe</i> .....	170
Tabela 21. <i>Medidas de ajuste do modelo</i> .....	171

Tabela 22. <i>Resultados das estimativas</i> .....	171
----------------------------------------------------	-----

## Sumário

<b>1 Introdução geral.....</b>	<b>13</b>
<b>1.1 Escopo da Tese .....</b>	<b>19</b>
<b>2 Padrões de desempenho de marcas de apps – Estudo 1.....</b>	<b>25</b>
<b>2.1 Padrões de lealdade comportamental.....</b>	<b>28</b>
<b>2.2 Padrões de compartilhamento de consumidores – Lei da compra duplicada.....</b>	<b>31</b>
<b>2.3 Métodos.....</b>	<b>33</b>
2.3.1 Amostra.....	34
2.3.2 Tratamento e análise dos dados.....	35
<b>2.4 Resultados.....</b>	<b>38</b>
2.4.1 Padrão do duplo risco aplicado a marcas de aplicativos.....	40
2.4.2 Compartilhamento de consumidores entre marcas de aplicativos.....	42
<b>2.5 Discussão dos resultados .....</b>	<b>44</b>
<b>2.6 Considerações Finais .....</b>	<b>46</b>
<b>3 O efeito da força da marca no desempenho de marcas de apps - Estudo 2 .....</b>	<b>49</b>
<b>3.1 Força da marca pela abordagem analítico-comportamental.....</b>	<b>50</b>
<b>3.2 Métodos.....</b>	<b>55</b>
3.2.1 Amostras .....	56
3.2.2 Tratamento e análise dos dados.....	57
<b>3.3 Resultados.....</b>	<b>59</b>
3.3.1 Estágio de adoção .....	61
3.3.2 Estágio de uso efetivo .....	61
<b>3.4 Discussão dos resultados .....</b>	<b>62</b>
<b>3.5 Considerações Finais .....</b>	<b>63</b>
<b>4 Comportamento de uso de marcas de aplicativos: influência de variáveis situacionais - Estudo 3 .....</b>	<b>66</b>
<b>4.1 Cenário de consumo de marcas de aplicativos .....</b>	<b>69</b>
4.1.1 Estímulos da dimensão espacial.....	70
4.1.2 Estímulos Temporais .....	74
4.1.3 Estímulo Social.....	75
<b>4.2 Experiência Mobile do Consumidor .....</b>	<b>76</b>
<b>4.3 Métodos.....</b>	<b>80</b>
4.3.1 Amostra.....	80
4.3.2 Tratamento e análise dos dados.....	80

<b>4.4 Resultados.....</b>	<b>84</b>
4.4.1 Frequência de Uso .....	84
4.4.2 Alteração do Repertório.....	86
<b>4.5 Discussão dos resultados .....</b>	<b>89</b>
<b>4.6 Considerações finais .....</b>	<b>90</b>
<b>5 Conclusão geral .....</b>	<b>93</b>
<b>Referências.....</b>	<b>99</b>
<i>Apêndice A – Delineamento do projeto de pesquisa: mBehavior App.....</i>	<i>124</i>
<i>Apêndice B – Modelo de NBD-Dirichlet aplicado ao uso de marcas de aplicativos.....</i>	<i>137</i>
<i>Apêndice C – Duplicação para marcas de aplicativo por categoria .....</i>	<i>139</i>
<i>Apêndice D – Indicador de força da marca: Proposição da medida para marcas de aplicativos .....</i>	<i>142</i>
<i>Apêndice E – Resultados dos Modelos de Regressão Quantílica.....</i>	<i>153</i>
<i>Apêndice F – Tipologia de configuração de intensidade de acesso ao longo do dia .....</i>	<i>159</i>
<i>Apêndice G – História de aprendizagem do consumidor: proposição de perfis latentes de experiência mobile do consumidor.....</i>	<i>163</i>

## 1 Introdução geral

O comportamento de escolha de marcas é um dos tópicos centrais da ciência de marketing (MSI, 2016, 2018, 2020). A relação entre consumidores e marcas tem sido um tópico de pesquisa fértil há décadas à medida que a complexidade dessas relações continua a gerar novos rumos de pesquisa intrigantes e frutíferos (Keller, 2020).

Uma corrente de pesquisa sob a abordagem de marketing baseado em evidência (Ehrenberg, 1988; Sharp, 2014), especializou-se na investigação empírica de padrões de escolha do consumidor, com base, majoritariamente, em dados reais de compras obtidos de painéis de consumidores. Estudiosos sob essa abordagem descobriram vários padrões sistemáticos de escolha do consumidor e parâmetros de desempenho da marca ao examinarem padrões de comportamento ao nível agregado da marca, considerando métricas comumente adotadas por empresas para avaliar seu desempenho no mercado (*e.g.*, market share, penetração e frequência média de compra da marca) (cf. Driesener & Rungie, 2022; Ehrenberg et al., 2004; Scriven et al., 2017; Sharp et al., 2012).

Essa corrente se baseia no trabalho iniciado e/ou inspirado por Ehrenberg na década de 1950 (*e.g.*, Chatfield et al., 1966; Ehrenberg, 1959; Ehrenberg & Goodhardt, 1958a, 1958b, 1970), com princípios norteadores em epistemologia indutiva (*bottom-up*), que propõe primeiro descobrir fenômenos de marketing generalizáveis (*i.e.*, foco no o quê, onde, como e quanto) antes de pensar em elaborar modelos teóricos complexos (*i.e.*, foco no porquê). Os estudiosos argumentam que generalizações empíricas – padrões/regularidades que se repetem em várias condições e mercados (Bass, 1995; Ehrenberg, 1995; Lindsay & Ehrenberg, 1993) –, contribuem para uma formação mais sólida da base de conhecimento para a ciência de marketing (Sharp, 2014). Em outras palavras, cientistas de marketing desta corrente procuram padrões semelhantes a leis em diferentes configurações de compra da marca, centrando na previsão do futuro (como um teste de teoria) e a identificação das condições de contorno do conhecimento (*e.g.*, quando os padrões se aplicam ou não) (Ehrenberg et al., 2004; Scriven et al., 2017; Sharp, 2014).

Pelo prisma da abordagem de marketing baseado em evidências, é proposto que, ao analisar o desempenho da marca com base na relação entre o tamanho da marca (penetração e market share) e a frequência média de compra da marca, seria possível identificar padrões de lealdade

comportamental (*e.g.*, Lei do Duplo Risco) e compartilhamento da base de consumidores (Lei da Compra Duplicada) da marca (Ehrenberg et al., 2004; Sharp, 2014). Em relação ao padrão de compartilhamento da base de consumidores – Lei da Compra Duplicada – que aponta que as marcas compartilham seus consumidores com todas as outras marcas intra-categoria (sobreposição das bases de consumidores) de acordo com o tamanho delas (*i.e.*, penetração da marca) (cf. Anesbury et al., 2022; Dawes, 2016a, 2016b; Ehrenberg, 1988; Ehrenberg & Goodhardt, 1968b; Scriven et al., 2017). Já em relação aos padrões de lealdade comportamental, pode-se mencionar a Lei do Duplo Risco que assinala que marcas com menor market share possuem menos compradores do que as alternativas mais populares da categoria e, em geral, são consumidas com um pouco menos de frequência – isto é, marcas menores são punidas duplamente (cf. Dawes et al., 2017; Ehrenberg, 1988; Ehrenberg et al., 1990, 2004; Ehrenberg & Goodhardt, 2002; Graham et al., 2017; Phua et al., 2020).

Ao mudar o nível de análise para o consumidor, estudiosos sob essa abordagem demonstraram, consistentemente, que apenas uma pequena proporção de consumidores de uma marca específica são compradores 100% leais da marca intra-categoria ao longo de uma sequência de compras (*e.g.*, período de um ano), evidenciando, por conseguinte, o padrão de que a maioria dos consumidores possuem repertório de marcas – que condiz com a compra repetida de uma pequena seleção de marcas de uma categoria de bens ao longo de um período (*e.g.*, um ano) – e não, necessariamente, tomam qualquer decisão consciente de rejeitar ou mudar uma marca pela outra (cf. Driesener & Rungie, 2022; Ehrenberg et al., 1990, 2004; Ehrenberg & Goodhardt, 1970; Goodhardt et al., 1984; Sharp et al., 2012). Ehrenberg et al. (2002, 2004) acrescentam que os repertórios pessoais são formados por marcas que recebem lealdade comportamental dividida, em que uma marca geralmente será adquirida com mais frequência do que outra. Esses padrões de compra do consumidor já foram replicados em diversas categorias de produtos e serviços (*e.g.*, de sopa a gasolina e serviços financeiros) e em diferentes países (*e.g.*, Austrália, Japão, Reino Unido e Estados Unidos) (cf. Driesener & Rungie, 2022; Ehrenberg et al., 2004; Scriven et al., 2017; Sharp et al., 2012).

Em alguns dados momentos os consumidores tendem a modificar seu repertório, incluindo e/ou parando de consumir uma marca do seu conjunto de preferências (Driesener et al., 2022; Ehrenberg et al., 2004; Trinh, 2014). Essa modificação pode ser denominada como “alteração do

repertório de marcas”. O entendimento de como e por que os consumidores tomam essas decisões de escolhas de marcas em torno da formação do seu repertório seria útil aos profissionais de marketing para o planejamento de estratégias, como direcionamentos para aumentar a taxa de retenção de consumidores e promover o crescimento da marca.

Diferentes fluxos de pesquisas têm proposto explicar e avançar o conhecimento referente às relações consumidor-marca, porém a grande maioria desconsidera que os consumidores possuem repertório de marcas (Fetscherin & Heinrich, 2015; Khamitov et al, 2019). Contudo, um fluxo de pesquisa que tem investigado essas relações sob a abordagem da perspectiva comportamental tem proposto elucidar como e por que os consumidores escolhem as marcas que compõem o repertório de compra e como as marcas são selecionadas dentro desses repertórios, revelando, por conseguinte, padrões comportamentais de preferências dos consumidores (e.g., Foxall et al., 2004; Oliveira-Castro et al., 2005b, 2006; Oliveira-Castro & Foxall, 2017; Oliveira-Castro et al., 2016; Porto & Oliveira-Castro, 2015).

Esses estudiosos têm se apoiado no modelo de perspectiva comportamental (BPM) (cf. Foxall, 1990, 2015), um modelo teórico-metodológico que visa explicar o comportamento do consumidor em relação ao seu contexto. O BPM considera que o comportamento do consumidor é motivado por variáveis situacionais – fatores da história de aprendizagem do indivíduo (efeitos cumulativos das consequências de escolhas passadas) e do cenário de consumo atual (estímulos físicos, sociais, temporal e regulatório). Quando essas variáveis se inter-relacionam sinalizam prováveis consequências reforçadoras (se mantiverem ou aumentarem o comportamento subsequente) e/ou punitivas (se diminuïrem o comportamento subsequente) – contingentes ao comportamento de escolha da marca.

Essas consequências podem ser utilitárias ou informativas. As consequências utilitárias são mediadas pelo uso do bem, o qual consiste nos benefícios funcionais que o bem pode oferecer. Já as consequências informativas são mediadas pelo *feedback* de outras pessoas acerca do desempenho do consumidor (cf. Foxall, 1990, 2015), estando relacionadas a elementos simbólicos (e.g., *status* sociais, exclusividade, autoestima e prestígio). Tais consequências determinarão a taxa de ocorrência de comportamentos semelhantes no futuro, por exemplo, a escolha de uma marca (cf. Foxall, 2009, 2010, 2015; Foxall et al., 2004; Foxall & Yani-de-Soriano, 2005; Oliveira-Castro



et al., 2016; Porto & Oliveira-Castro, 2013b). Essas consequências são salientadas pelo cenário de compra/consumo presente no instante de uma nova escolha.

A configuração do cenário abarca a fonte e natureza de controle que os estímulos exercem sobre o comportamento. Os estímulos presentes no cenário de consumo de marcas podem estar sob o controle relativo de gestores e consumidores (Foxall, 1998; Foxall et al., 2004, 2021). Por exemplo, levar um acompanhante ao fazer compras é um estímulo social sob o controle relativo do consumidor, enquanto características da marca e do produto/serviço são estímulos discriminativos programados e estão sob o controle relativo de gestores. Cada um deles pode salientar de forma diferente a sinalização da ocorrência de reforçadores ou punidores após um novo comportamento.

As abordagens de perspectiva comportamental e de marketing baseado em evidência, apesar de suas correntes teóricas serem distintas, apresentam afinidades e podem ser consideradas complementares (Foxall et al., 2021) para o avanço do conhecimento em torno das relações consumidor-marca, especialmente no contexto de compra da marca em mercados offline (e.g., bens de consumo de movimento rápido – FMCG) em que a maioria das pesquisas sob essas abordagens foram conduzidas (Driesener et al., 2022; Foxall et al., 2021). Ambas as abordagens põem luz na premissa de que os consumidores possuem repertório de marcas ao considerarem um mercado focal de investigação. E, ao partirem desse pressuposto, têm auxiliado na evidenciação de padrões sistemáticos de escolha do consumidor e desempenho de marcas no contexto de compra da marca.

Embora os estudos desenvolvidos sob essas abordagens apresentem avanços significativos para a ciência de marketing, elas não foram, aparentemente, até o momento, postas em conjunto numa mesma investigação empírica. E há espaço para novas pesquisas de campo que avancem o entendimento se esses padrões de desempenho e comportamento de compra de marcas (Porto & Oliveira-Castro, 2015) também se aplicam/estendem ao nível do uso efetivo de marcas, bem como ampliando o contexto de investigação para mercados no âmbito do mundo digital (e.g., marcas de aplicativos mobile), já que pesquisas sob tais abordagens são incipientes e tem sido destacado como prioridade de pesquisa pelo *Marketing Science Institute* (MSI) para avançar na compreensão das interações consumidor-marca (MSI, 2016, 2018, 2020).

O rápido avanço e difusão das tecnologias de informação e comunicação (TICs) têm contribuído para mudanças no cenário de negócios. Por conseguinte, as tecnologias móveis ampliaram o alcance a informações comportamentais e contextuais pelos pesquisadores e gestores,

permitindo a extração de insights sobre fenômenos de marketing de uma forma que era impraticável no passado (e.g., as interações consumidor-marca no contexto de uso) e oferecem um terreno fértil com múltiplas direções para avançar nas teorias e práticas de marketing (Keller, 2021, 2022; Saura et al., 2017).

Neste contexto, a abordagem de *mobile marketing* – que envolve a geração de valor, comunicação e promoção de múltiplas vias entre empresas e seus clientes, usando o meio onipresente de dispositivos, canais ou tecnologias móveis (Lamberton & Stephen, 2016; Shankar & Balasubramanian, 2009) –, tem crescido em importância para os gestores, independentemente do negócio fim (Fong et al., 2015; Kannan & Li, 2017; Shankar et al., 2010), tendo sua consideração estratégica acelerada devido à crise global de saúde e financeira causadas pela pandemia Covid-19 (John & Thakur, 2021; MSI, 2020; Stocchi et al., 2021).

As empresas estão cada vez mais envolvidas em redes dinâmicas que compreendem o complexo ecossistema *mobile* (Kim et al., 2021). O ecossistema *mobile*, em uma visão ampla, compreende muitas camadas de uma rede extensa e complexa de atores públicos e privados (heterogêneos) que interagem entre si, de forma direta ou indireta, para fornecer uma ampla gama de bens *mobile* aos clientes finais (Basole, 2009; Basole & Karla, 2011; Lindgren et al., 2015).

Pesquisadores de marketing, de modo geral, têm solicitado mais estudos neste âmbito que abrangem a gestão de marcas e a interatividade marca-consumidor (cf. Hair & Sarstedt, 2021; MSI, 2020; Stocchi et al., 2021; Tong et al., 2020), uma vez que, dada a onipresença dos dispositivos móveis e os aplicativos expandirem suas funcionalidades, têm proporcionado a oportunidade de as empresas (independente do seu porte) estarem cada vez mais conectadas em qualquer lugar e momento com os consumidores (Keller, 2021; Stocchi et al., 2021) e de diferentes maneiras por meio dos aplicativos, como: i) uma oferta digital autônoma de marca; ii) uma extensão da identidade de marca pré-existente online/offline com estratégia de realizar diferentes objetivos de marketing; e iii) um novo meio de publicidade por meio de apps de terceiros/parceiros (Gokgoz et al., 2021; Mondal & Chakrabarti, 2021; Stocchi et al., 2021).

De uma perspectiva de marketing, os aplicativos *mobile* (apps) são produtos digitais que oferecem distintas funcionalidades e soluções para os usuários (Liu et al., 2014; McLean, 2018; Natarajan et al., 2018). Em geral, eles exibem de forma proeminente uma identidade de marca, podendo ser expressa por meio do nome do aplicativo, ícone da marca, logotipo, aparência e/ou

valores que estão presentes no decorrer de toda a experiência do usuário com o app (Bellman et al., 2011; Chen et al., 2019).

O mercado de apps tem atraído a atenção de diferentes setores devido às possíveis oportunidades lucrativas. Porém, esse mercado é norteado por especificidades das plataformas e caracterizado por hipercompetitividade, no qual apenas uma pequena parcela das marcas ultrapassam o estágio de adoção pelo consumidor (Gokgoz et al., 2021; Tavalaei & Cennamo, 2021). O estágio de adoção do aplicativo condiz com as experiências do consumidor intrínsecas ao processo de tomada de decisão posterior às predisposições iniciais de considerar uma marca de app que sinalize a aquisição do bem (i.e., download ou compra). Esse estágio recebeu uma atenção considerável da academia (Stocchi et al., 2021; Tang, 2019), em particular utilizando modelos de adoção de tecnologia e suas extensões (Al-Nabhani et al., 2022; Gera et al., 2020).

Entretanto, apesar de ser necessária e fundamental a adoção dos apps (aquisição), ela não é suficiente para garantir o sucesso, ou seja, a rentabilidade deles. Tendo em vista que a maior parcela da receita (direta/indireta) advém do uso contínuo do app, o entendimento, pelos profissionais da área, dos possíveis padrões de desempenho de uso de marcas de aplicativo, e de como e por que os consumidores se envolvem e continuam utilizando aplicativos, torna-se essencial para o sucesso desse modelo de negócio (cf., Li et al., 2020b; Stocchi et al., 2021; Tang, 2019).

O estágio de uso efetivo, também conhecido como estágio de pós-adoção, consiste na interação repetida do consumidor com o app (Stocchi et al., 2021; Tang, 2019), englobando as múltiplas experiências do consumidor enquanto continuar usando o app e as consequências resultantes para as partes envolvidas. As oportunidades de interação continuada (repetida) com os consumidores são particularmente importantes para as marcas. Porém, pouco se sabe sobre a dinâmica competitiva das marcas nesse estágio (cf. Gera et al., 2020; Stocchi et al., 2021; Tang, 2019).

Em síntese, estudiosos têm apontado que as lojas de apps são pontos de distribuição sempre ativos, podendo ser consideradas como o principal meio de comunicação e feedback consumidor-marca crucial para a sobrevivência das marcas neste mercado, o que torna primordial a consideração do ecossistema organizacional circundante (e.g., marca – ponto de distribuição – consumidor) nesse contexto de investigação (Gera et al., 2020; Stocchi et al., 2021; Tang, 2019).

Neste direcionamento, estudiosos (e.g., Al-Nabhani et al., 2022; Dinsmore et al., 2021; Gera et al., 2020; Hair & Sarstedt, 2021; John & Thakur, 2021; McLean et al., 2020; Stocchi et al., 2021; Tang, 2019; Tong et al., 2020), considerando a abrangência e crescimento da economia de aplicativos, apontam que há muito o que avançar na pesquisa acadêmica de uma perspectiva de marketing – considerando o ecossistema organizacional circundante e os diferentes pontos de interação com o consumidor (e.g., estágio de adoção e estágio de uso efetivo do app), principalmente com base em dados comportamentais. Esses pesquisadores de marketing, de modo geral, têm solicitado mais pesquisas que elucidem como as marcas de aplicativos competem e evidenciem como e quais variáveis situacionais impulsionam o desempenho e o uso de marcas de aplicativos.

### **1.1 Escopo da Tese**

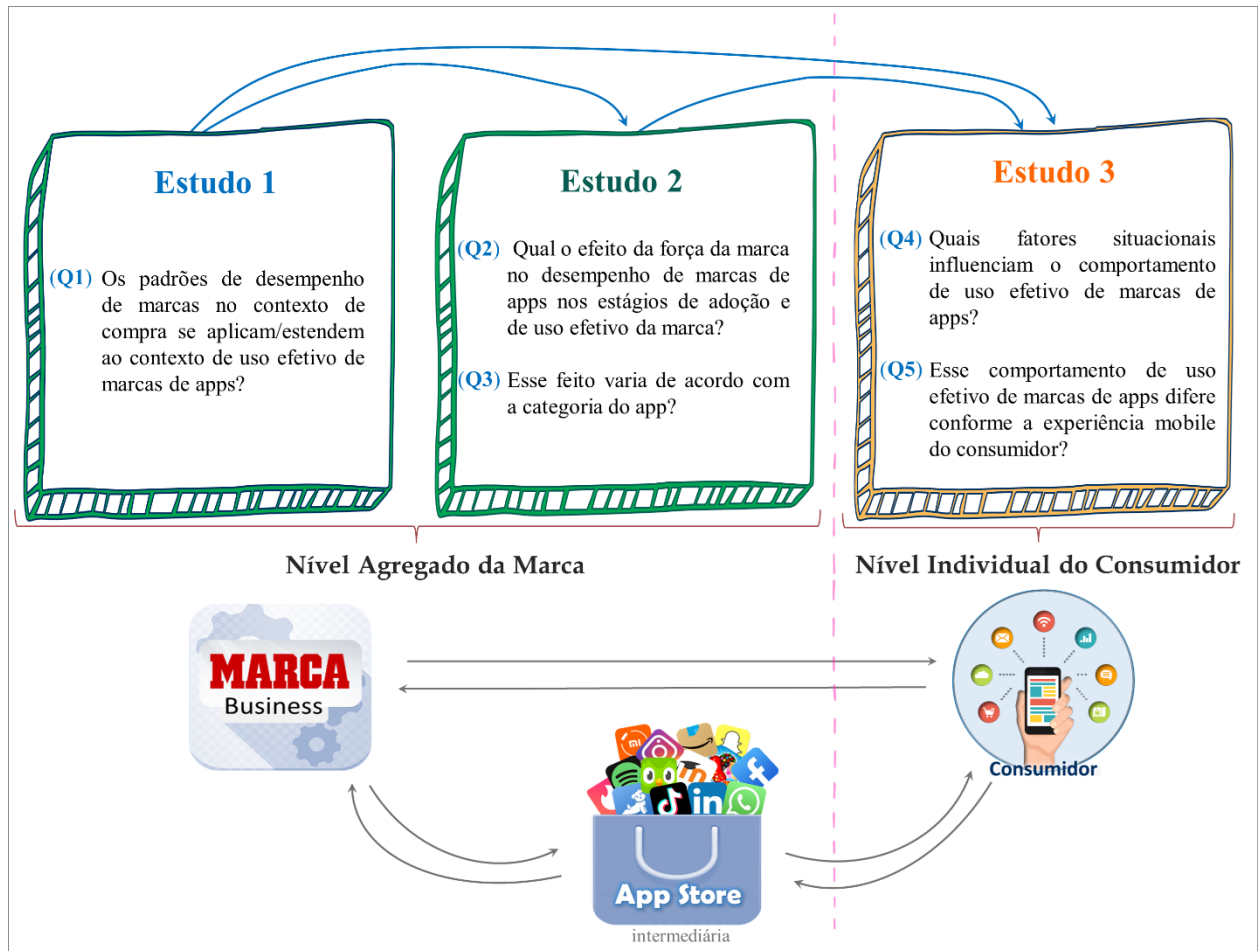
Com motivação nessas lacunas, a presente tese pretende integrar e avançar o conhecimento de marketing sobre o desempenho competitivo e uso de marcas de aplicativos e seus possíveis antecedentes situacionais. Para alcançar esse propósito, esse estudo apoiou-se em duas abordagens robustas que se complementam. A saber, a abordagem de marketing baseado em evidências e a abordagem da perspectiva comportamental. Nesse sentido, esta pesquisa de campo busca avançar o entendimento se esses padrões de desempenho de marcas e de comportamento de compra de marcas também se aplicam/estendem ao desempenho e comportamento no nível do uso efetivo de marcas de aplicativos. Deste modo, tem-se como pergunta de pesquisa da tese: como as marcas de aplicativos competem e como e quais variáveis situacionais impulsionam o desempenho e o uso de marcas de aplicativos?

Na Figura 1 é apresentada, de forma esquemática, a abrangência desta tese. Os seus blocos de construção são (1) o desempenho de marcas de aplicativos no estágio de uso efetivo, (2) a força da marca de aplicativos atentando ao ecossistema organizacional circundante e (3) a interação consumidor-marca no nível do consumidor mobile. Conforme pode ser observado, os estudos abrangem diferentes níveis de análise (agregado da marca e individual do consumidor) e são norteados por questões-chaves de pesquisa em aberto na literatura. Uma discussão mais detalhada

da literatura relevante, e o raciocínio para cada questão de pesquisa, pode ser encontrada nos capítulos de cada estudo específico.

### Figura 1

Visão geral da tese – questões-chave de pesquisa em aberto na literatura



*Nota.* As setas em azul representam o direcionamento do fluxo de avanço dos estudos; e a linha tracejada em rosa representa o limite teórico dos níveis de análises realizadas.

No primeiro bloco (Estudo 1), observou-se que o desempenho de marcas de apps no estágio de uso efetivo, com base em dados reais, no geral, não tem sido relatado por estudiosos. Segundo estudos recentes de revisão da literatura, um maior esforço foi despendido na investigação do desempenho de marcas de apps isoladamente sem considerar o seu contexto competitivo (Stocchi et al., 2021); e uma grande limitação de estudos no nível da marca se refere ao fato de a maioria ter examinado as atitudes reivindicadas pelos consumidores em oposição ao comportamento real de consumo de marcas de apps (Gera et al., 2020; Stocchi et al., 2021; Tang, 2019).

Estudiosos sob a abordagem de marketing baseado em evidências (e.g., Ehrenberg, 1995; Ehrenberg et al., 2004; Goodhardt et al., 1984; Lindsay & Ehrenberg, 1993; Sharp, 2014), há tempos expressaram a necessidade de replicação contínua e extensão de generalizações empíricas de marketing, como os padrões de desempenho de marcas no contexto de compra, ao que tangencia o tamanho da marca (*i.e.*, market share e penetração), lealdade comportamental (e.g., Lei do Duplo Risco) e compartilhamento da base de consumidores (Lei da Compra Duplicada) da marca. Em consonância, estudos recentes complementam que é com respaldo no acúmulo de descobertas empíricas, consistentemente verificadas, que o conhecimento factual com base científica pode avançar (Babin et al., 2021, 2022), uma vez que fornece uma maior oportunidade para determinar as condições de contorno para generalizações empíricas (Babin et al., 2021; Driesener & Rungie, 2021; Graham et al., 2017, 2019; Trinh & Dawes, 2020; Uncles & Kwok, 2013).

Contudo, replicações diferenciadas de estudos na área de marketing ainda são preambulares (Babin et al., 2021; Driesener et al., 2021; Graham et al., 2019; Trinh & Dawes, 2020). Considerando esse gap, o presente estudo pretende avançar estudos anteriores sobre desempenho de marcas e o uso efetivo de marcas, examinando padrões de desempenho de marcas de aplicativos no estágio de uso efetivo, por meio de extensão e replicação de generalizações empíricas de marketing (cf. Lindsay & Ehrenberg, 1993; Tsang & Kwan, 1999). Neste direcionamento, no Estudo 1 se propôs responder à seguinte questão de pesquisa: (Q1) os padrões de desempenho de marcas no contexto de compra se aplicam/estendem ao contexto de uso efetivo de marcas de apps?

No segundo bloco (Estudo 2), com base na abordagem comportamental que postula que ao considerar uma estrutura analítica integrada que levem em conta medidas do comportamento do consumidor que informem as estratégias de marketing, a avaliação do desempenho da empresa refletiria o efeito que as marcas têm sobre os consumidores (cf. Foxall et al., 2021), o que possibilitaria avançar o conhecimento sobre fatores situacionais que impulsionam esse desempenho.

Estudos sob essa perspectiva (e.g., Oliveira-Castro et al., 2008; Porto & Lima, 2015; Porto & Oliveira-Castro, 2015), baseados na compra da marca, têm revelado que a força da marca, que está sob o controle de gestores, prevê o desempenho competitivo das marcas (e.g., market share e penetração) e que isso pode variar conforme a categoria do bem (*i.e.*, possível efeito de moderação). Contudo, pouco se sabe sobre o desempenho de marcas de aplicativos nos diferentes pontos de

contato com o consumidor com base em dados reais. Os efeitos das ações de *branding*, por conseguinte, também não foram adequadamente considerados (Tang, 2019).

Estudos anteriores, em sua maioria, concentraram-se em aspectos de *branding* sem considerar o contexto competitivo das marcas de apps e/ou os diferentes estágios de interação consumidor-marca, assim suposições robustas sobre a influência do valor intangível da marca nos resultados das marcas neste mercado ainda não são suportadas (Gera et al., 2020; Stocchi et al., 2021; Tang, 2019). Dessa forma, no Estudo 2, buscou-se responder às seguintes perguntas de pesquisas: (Q2) qual o efeito da força da marca no desempenho de marcas de apps nos estágios de adoção e de uso efetivo de marcas? (Q3) E esse efeito varia de acordo com a categoria do app?

No terceiro bloco (Estudo 3) partiu-se do pressuposto de Keller (2021) de que as marcas e os consumidores estão inextricavelmente ligados e, ao mesmo tempo, de lados opostos, ressaltando que para um entendimento mais completo das marcas e *branding*, nesse contexto em rápida evolução, é necessário ter insights ainda mais aguçados sobre os consumidores e o comportamento do consumidor em nível desagregado.

Em mutualidade pelo prisma da perspectiva comportamental, estudos têm elucidado a pertinência de ampliar o escopo de pesquisas de marketing que relacionem antecedentes do nível individual do comportamento de compra do consumidor ao nível agregado de análise da marca para esse fim (Foxall et al., 2021; Oliveira-Castro et al., 2008; Porto & Oliveira-Castro, 2015). Assim, na presente tese, considerando a chamada emergente de estudos que contribuam para a evidência de antecedentes de uso de marcas de apps que vão além das características tecnológicas do app (Al-Nabhani et al., 2022), propõe-se testar o caminho inverso ao levar a variável força da marca para o nível do consumidor como uma medida proximal de reforço informativo da marca (cf. Oliveira-Castro et al., 2008).

Em suma, a análise do comportamento do consumidor enfatiza a influência de variáveis situacionais, localizando o comportamento do consumidor no espaço e no tempo. Isto é, possui foco na compreensão do comportamento do consumidor em relação ao seu contexto (cf. Foxall, 1990, 2015). E, segundo Porto e Oliveira-Castro (2013b), essa influência pode variar conforme a experiência passada do consumidor com a marca. Assim sendo, acredita-se que o comportamento de uso de marcas é influenciado por estímulos situacionais que podem estar sob o controle relativo do consumidor (e.g., estímulo temporal e social) e sob o controle de gestores de diferentes

instâncias do ecossistema mobile que programam o cenário virtual de interação consumidor-marcas de apps e as consequências (ou seja, benefícios) ofertadas por essas marcas (Foxall, 2015; Foxall et al., 2021), porém essa influência poderia variar de acordo com a experiência mobile do consumidor. Neste direcionamento, no Estudo 3, propõe-se responder às seguintes questões: (Q4) Quais fatores situacionais influenciam o comportamento de uso efetivo de marcas de apps? (Q5) E esse comportamento de uso efetivo de marcas de apps difere conforme a experiência mobile do consumidor?

Assim, diante do exposto, o objetivo geral da tese é **estimar padrões de desempenho e uso de marcas de aplicativos e seus antecedentes situacionais**. Os objetivos específicos da tese estão contidos nos estudos e são:

- Examinar se as marcas de aplicativos seguem padrões de desempenho de marcas bem estabelecidos na literatura em contexto de compra, ao que tangencia o tamanho da marca, lealdade comportamental e compartilhamento da base de consumidores – Estudo 1.
- Analisar o impacto da força da marca no desempenho de marcas de aplicativos nos estágios de adoção e uso efetivo pelo consumidor, testando moderação da categoria do aplicativo – Estudo 2.
- Analisar a influência de variáveis situacionais sob o controle relativo do consumidor (estímulo temporal e social) e de gestores (estímulos do ambiente virtual) sobre o comportamento efetivo de uso de marcas de aplicativos (frequência de uso e alteração do repertório) pelo consumidor, testando moderação da experiência mobile do consumidor – Estudo 3.

Para o alcance dos objetivos, a presente tese realizou uma triangulação metodológica, considerando a combinação de distintas formas e fontes de coleta de dados, níveis, recortes temporais e validações (Gera et al., 2020; Stocchi et al., 2021; Tang, 2019). Devido a incipiência de painéis de dados comportamentais de uso de marcas de aplicativos disponíveis para a condução dos estudos, um projeto de pesquisa com delineamento longitudinal de campo foi conduzido com o propósito de projetar, validar e implementar um instrumento para coletar dados anonimizados de smartphones em condições de ambiente natural (vida cotidiana) (projeto mBehavior App, consulte Apêndice A).



Na presente tese optou-se pela consideração do contexto do mercado brasileiro de aplicativos, uma vez que, apesar de o Brasil estar entre os cinco maiores mercados do mundo de apps em número de downloads (AppsFlyer & App Annie, 2021), quantitativo de usuários ativos de smartphones (Statista, 2020) e tempo despendido em dispositivos móveis (App Annie, 2021), pesquisas considerando esse mercado ainda são exordiais. Essa escolha também se justifica devido a estudiosos (cf. Paul, 2019; Ozretic-Dosen et al., 2022; Sheth, 2011) argumentarem que a consideração das condições ambientais significativas das economias emergentes pode contribuir para avanços conceituais, metodológicos e empíricos da área.

Assim, em conjunto, os três estudos contribuem para o avanço do conhecimento em torno do desempenho de marca e o comportamento de uso de marcas no contexto do mercado mobile app. De forma abrangente, esta tese fornece insights sobre a relação consumidor-repertório de marca nos estágios de adoção e de uso efetivo com base em dados reais.

Essa tese está organizada em cinco capítulos: após esse capítulo introdutório, são apresentados três capítulos referentes a cada um dos estudos anteriormente descritos e, por fim, as considerações finais.

## 2 Padrões de desempenho de marcas de apps – Estudo 1

O desempenho da marca é uma medida de sucesso relativo em um mercado (Ehrenberg et al., 2004). Como tal, investigar o desempenho de marca, considerando a sua categoria de bem como âmbito principal de competição, torna-se primordial para avançar o conhecimento dentro da área de marketing (Ehrenberg et al., 2004; Oliveira-Castro et al., 2008; Porto, 2019). No mercado mobile apps, estudo recente (Li et al., 2020b) aponta que as categorias de apps são singulares, pois contêm conjuntos de apps com funcionalidades semelhantes intra que normalmente diferem entre categorias, bem como diferem em maturidade – grau de popularidade (penetração).

No entanto, nesse mercado um maior esforço foi despendido na investigação do desempenho de marcas de apps isoladamente sem considerar o seu contexto competitivo primário (a categoria) (Stocchi et al., 2021), sendo direcionado um maior foco às marcas de apps como uma extensão da identidade de marca pré-existente *online/offline* (Gokgoz et al., 2021; Stocchi et al., 2021). Tal fato revela um gap de pesquisa, pois todas as marcas de apps competem para integrarem o repertório de uso dos consumidores, independentemente de serem consideradas uma oferta digital autônoma de marca (e.g., Snapchat e 12min - Resumos de Livros) ou uma extensão de marca pré-existente *online/offline* (e.g., Adidas, Facebook e Sou UFMS).

O desempenho da marca no mercado de apps vai além das abordagens tradicionais, geralmente considerando o ponto de distribuição. Nesse mercado os profissionais de marketing são desafiados a monitorar o desempenho de marcas em diferentes estágios (de adoção e de uso efetivo da marca), uma vez que, no estágio de adoção, apesar da aquisição do app pelo consumidor (download/compra) seja fundamental e necessária para as marcas de apps, não há garantias de sucesso e rentabilidade. Torna-se essencial, também, o monitoramento do desempenho no estágio de uso efetivo do app, considerando o contexto competitivo da marca (Rutz et al., 2019; Stocchi et al., 2021; Tang, 2019). Porém, pouco se sabe sobre a dinâmica competitiva das marcas além do contexto da loja de app, em especial com dados comportamentais (cf. Gera et al., 2020; Stocchi et al., 2021; Tang, 2019).

Estudo recente (Al-Nabhani et al., 2022) sobre a intenção de continuar usando marcas de apps corrobora com estudos anteriores ao evidenciar que cada interação do consumidor com app é relevante para o sucesso da marca (e.g., McLean et al., 2020; Stocchi et al., 2017, 2019). Além

desta constatação, foi identificado que, embora os consumidores possam aproveitar a experiência de usar o app, gastar mais tempo no app do que o necessário pode resultar em insatisfação e levar a descontinuação do app. Tal constatação lança luz que, a depender do propósito do app, a frequência de acesso ao app (i.e., incidência de uso) é mais relevante aos gestores do que propriamente o tempo excessivo dentro do app (i.e., volume por acesso), revelando indícios de que a incidência de uso pode oferecer melhor explicação acerca do desempenho de marcas no estágio de uso efetivo, mas que, no entanto, carece de mais evidências.

Tais achados vão ao encontro do que tem sido argumentado por cientistas de marketing, apoiados em generalizações empíricas no contexto de compra, de que os critérios de mensuração de métricas de desempenho – incidência e volume (de compra da marca) – apesar de apresentarem diferenças sutis, podem mudar consideravelmente a interpretação de padrões e possíveis comparações. Argumenta-se que a consideração da incidência de compras possibilita um melhor entendimento da recorrência de compra da marca, permitindo avaliar as marcas independentemente de particularidades (cf. Driesener & Rungie, 2022; Ehrenberg et al., 2004; Ehrenberg & Goodhardt, 1970).

Nesta perspectiva, estudiosos com base na abordagem de marketing baseado em evidências têm proposto a estimação das medidas de desempenho da marca ao interpretar a dinâmica do mercado e padrões de compra dos consumidores com auxílio do modelo de NBD-Dirichlet proposto por Ehrenberg. O modelo captura uma série de generalizações empíricas importantes sobre o comportamento de compra, incluindo repertório de marcas, lei do duplo risco (padrões de lealdade comportamental) e da lei de compra duplicada (padrão de compartilhamento da base de consumidores), que já foram replicadas em diversas categorias de produtos e serviços e em diferentes mercados (Driesener & Rungie, 2022).

No contexto de compra repetida, o modelo assume que a lealdade comportamental à marca é uma função do tamanho da marca (penetração e market share) que reflete em popularidade (Ehrenberg et al., 2004; Sharp et al., 2012). E, embora os valores das métricas difiram entre as categorias, os padrões gerais que elas evidenciam não. Desse modo, o modelo tem sido considerado uma abordagem útil para compreender o comportamento, de maneira mais ampla, de compra repetida de marcas em diferentes mercados e contextos, possibilitando, assim, elucidar a estrutura de mercado de marcas (Driesener et al., 2017; Driesener & Rungie, 2022; Ehrenberg et al., 2004).

No contexto do mercado de apps, estudos recentes de revisão da literatura (Gera et al., 2020; Stocchi et al., 2021; Tang, 2019) apontam que uma limitação de estudos no nível da marca se refere ao fato de a maioria ter examinado as atitudes reivindicadas pelos consumidores em oposição ao comportamento real de consumo de marcas de apps. Logo, estudos com foco claro na dinâmica competitiva de marcas de apps no estágio de uso efetivo são exordiais. Em parte, essa insipiência se justifica, de modo geral, devido ao fato de que o desempenho de uso de marcas, com base em dados reais, também não tem sido relatado na literatura de marketing (Gera et al., 2020; Hanssens & Pauwels, 2016; Keller, 2021; Oh et al; 2020; Stocchi et al., 2021).

Contudo, o avanço acelerado das tecnologias no âmbito digital e abundância de dados gerados em diferentes níveis, em especial, nos pontos de contatos subsequentes consumidor-empresa, oportuniza o avanço desse conhecimento (Borges et al., 2021; Shah & Murthi, 2021). Portanto, diante do exposto, questiona-se: os padrões de desempenho de marcas no contexto de compra se aplicam/estendem ao contexto de uso efetivo de marcas de apps?

Para responder à pergunta de pesquisa serão mensurados três tipos de medidas de desempenho de marca: tamanho da marca (market share e penetração), lealdade comportamental e compartilhamento de consumidores sob a perspectiva da abordagem de marketing baseado em evidências. Métricas baseadas no mercado revelam melhor como a marca compete e podem contribuir para a definição de melhores estratégias para um crescer mais realista, isto é, construindo ativos baseados no mercado, possibilitando, assim, vislumbrar um panorama da estrutura competitiva (Ehrenberg et al., 2004).

Desse modo, avançando à literatura anterior, este estudo se concentra em **examinar se as marcas de aplicativos seguem padrões de desempenho de marcas bem estabelecidos na literatura em contexto de compra, ao que tangencia o tamanho da marca, lealdade comportamental e compartilhamento da base de consumidores.**

Este estudo segue organizado da seguinte forma: no próximo tópico é apresentado o referencial teórico referente a padrões de lealdade comportamental e compartilhamento de consumidores pela abordagem de marketing baseado em evidências, seguido dos métodos de pesquisa, abrangendo a adaptação das medidas de desempenho para o contexto de uso efetivo de marcas de apps. Por conseguinte, os resultados são apresentados, seguidos da discussão e contribuições dos achados. Por fim, as limitações e sugestões de pesquisas futuras são apresentadas.

## 2.1 Padrões de lealdade comportamental

A busca pela compreensão da lealdade à marca em contextos diversos gerou um número crescente de pesquisas com diferentes enfoques e abordagens. É uma temática que possui complexidades de natureza conceitual e prática, refletindo em uma pluralidade na forma como é definida e mensurada. As dimensões mais amplamente difundidas sob as quais a lealdade do consumidor à marca tem sido investigada são: comportamental e atitudinal (Bandyopadhyay & Martell, 2007; Dick & Basu, 1994; Oliver, 1999). Em suma, a lealdade atitudinal à marca concerne ao compromisso/disposição psicológica em relação a uma marca, como intenções de comprar e recomendar, sem necessariamente considerar a ocorrência do comportamento efetivo; e a lealdade comportamental à marca concerne ao comportamento sistemático de compra repetida da marca em um horizonte de tempo (Jacoby & Kyner, 1973; Oliver, 1999).

No que tange à lealdade comportamental à marca, Ehrenberg e colegas (e.g. Ehrenberg, 1991; Ehrenberg et al., 1990, 2004; Ehrenberg & Goodhardt, 2000, 2002; Goodhardt et al., 1984; Uncles et al., 1994), com auxílio do modelo de *NBD-Dirichlet*, constataram que apenas uma pequena parcela dos consumidores de uma determinada marca são compradores integralmente leais da marca em uma categoria de bem quando considerada uma sequência de compras (e.g. período de um ano). Ehrenberg et al. (2002, 2004) afirmam que, para bens de marcas consumidos com certa frequência, os consumidores de uma determinada marca compram singularmente outras marcas da sua seleção de preferências (repertório de preferências), no total, com mais frequência. Ou seja, os consumidores de uma marca X são, principalmente, consumidores de outras marcas da categoria que ocasionalmente compram a marca X.

Nesta perspectiva, estudiosos afirmam que, ao partir do pressuposto que os consumidores possuem repertório de compra de marcas, o tamanho do repertório pode ser considerado como uma medida natural de lealdade comportamental, pois quanto menor for o repertório maior será a lealdade às marcas que o compõe (e.g., Banelis et al., 2013; Dawes, 2008; Dawes et al., 2015; Sharp et al., 2002; Trinh, 2014; Trinh et al., 2017; Uncles & Lee, 2006). O tamanho médio do repertório de marcas intra-categoria em mercados de bens de consumo rápido (FMCG – *fast moving consumer goods*) é entre duas e três marcas por ano (Banelis et al., 2013; Dawes, 2008; Trinh,

2014). Banelis et al. (2013) constataram que, ao longo do tempo, esse tamanho médio anual tende a se manter e não varia consideravelmente entre as categorias. Com base nesses achados, os autores (Banelis et al., 2013) afirmam que o tamanho médio do repertório de marcas intra-categoria de um consumidor (agregado familiar) pode ser determinado observando poucas ocasiões de compras.

Porém, cabe acrescentar que o tamanho do repertório tende a variar menos entre os compradores leves do que entre compradores pesados da categoria (Trinh, 2014). E, à medida que os consumidores adquirem com mais frequência de uma determinada categoria de bens, seu repertório de marcas tende a ampliar (Bogomolova et al., 2019; Ehrenberg et al., 2004; Mundt et al., 2006; Sharp et al., 2002; Wright et al., 1998). Em síntese, os consumidores tendem a se manterem leais ao seu pequeno repertório de preferência. Considerando que essa tendência foi constatada em diferentes mercados, espera-se que no estágio de uso efetivo de marcas de apps também seja observada.

Padrões de lealdade comportamental à marca podem ser explicados com base na abordagem do *Double Jeopardy* (DJ – duplo risco), um dos padrões mais extensivamente testado e bem conhecido na área de marketing (Driesener & Rungie, 2022; Ehrenberg et al., 2004; Graham et al., 2017; Porto & Lima, 2015; Scriven et al., 2017; Sharp et al., 2012; Uncles et al., 2012). Essa generalização empírica, considerada praticamente como uma lei, atesta que marcas pequenas são punidas duplamente: possuem menos compradores do que as alternativas mais populares/maiores da categoria, e, em geral, são compradas com um pouco menos de frequência. Por outro lado, marcas maiores tendem a ter mais compradores e são compradas com um pouco mais de frequência (Dawes et al., 2017; Ehrenberg et al., 2004; Ehrenberg & Goodhardt, 2002; Graham et al., 2017; Phua et al., 2020).

O DJ contribui para análise da lealdade no nível individual da marca. O padrão de DJ possibilita descrever a relação entre a lealdade comportamental do consumidor e o tamanho da marca (participação de mercado e penetração), permitindo identificar o que seriam níveis normais ou teóricos de lealdade à marca, dado o tamanho da marca. O fenômeno de DJ tem se apresentado comum em mercados competitivos, em que as marcas geralmente são muito semelhantes quanto aos atributos dos bens, mas diferem consideravelmente em popularidade (i.e., participação de mercado) devido às possíveis estratégias de marketing que foram (ou são) adotadas por cada marca (Ehrenberg et al., 1990; Ehrenberg & Goodhardt, 2002).

Contudo, foi identificado que fatores de *marketing mix* e cenário de consumo podem contribuir para os diferentes níveis de vendas, que, por conseguinte, aparecem no padrão de DJ, porém raramente causam consideráveis diferenças adicionais na lealdade comportamental à marca (Dawes, 2018; Dowling & Uncles, 1997; Ehrenberg et al., 1990, 1994; Ehrenberg & Goodhardt, 2002; Scriven et al., 2017). O DJ tem revelado que, à medida que a participação de mercado e a penetração aumentam, o mesmo tenderá a ocorrer com a frequência média de compra e a lealdade exclusiva (Ehrenberg et al., 1990, 2004; Ehrenberg & Goodhardt, 2002; Fader & Schmittlein, 1993; Graham et al., 2017). Nesta conjuntura, o DJ tem sinalizado que a diferença entre marcas pequenas e grandes é, principalmente, no quantitativo de consumidores que elas possuem (i.e., penetração) (Ehrenberg, 1988; Ehrenberg et al., 2004; Graham et al., 2017).

A identificação do padrão de DJ pode ser aferida a partir das estimativas teóricas do modelo de *NBD-Dirichlet*, no qual os possíveis desvios entre as estimativas teóricas e observadas têm sido considerados normais se estiverem em torno de até 10%. Quando ultrapassam essa margem é recomendado que sejam investigados em particular para um melhor benchmark, pois podem revelar diferenciais de posicionamento da marca dentro da categoria (Ehrenberg et al., 1990, 2004; Ehrenberg & Goodhardt, 2002; Graham et al., 2017; Scriven et al., 2017).

Dois dos desvios mais conhecidos para o padrão de DJ são nicho e mudança de ritmo. Marcas de nicho são marcas com baixa participação de mercado, mas possuem um número de consumidores que são mais leais do que o esperado (Bhattacharya, 1997). A lealdade relativamente alta, geralmente, pode ser devido à presença pontual geográfica (Dawes et al., 2020; Pare & Dawes, 2012) e uma diferença funcional que atende às necessidades de um segmento de mercado específico (Bhattacharya, 1997; Kahn et al., 1988; Scriven et al., 2017).

Marcas de mudança de ritmo são marcas consumidas com menor frequência do que seria esperado, contudo possuem penetração maior do que o previsto. Há três causas comuns para esse tipo de desvio – sazonalidade, compra para terceiros e busca por variedade (Bhattacharya, 1997; Kahn et al., 1988; Scriven et al., 2017). No âmbito do mercado de mobile apps, a sazonalidade estaria relacionada ao uso de apps que são mais úteis em períodos específicos; e a compra para terceiros poderia ser interpretada como os apps instalados no dispositivo que tendem a serem usados apenas por outrem. Em síntese, seriam marcas usadas apenas ocasionalmente, podendo não fazerem parte do repertório regular de uso do consumidor (Scriven et al., 2017).

Embora o posicionamento de nicho e mudança de ritmo possam tornar as marcas refratárias a efeitos do DJ, eles são, consideravelmente, menos prevalentes do que o regimento da lei do duplo risco (Dowling & Uncles, 1997; Scriven et al., 2017). Contudo, no contexto de uso efetivo de marcas de aplicativos, pode ser excepcional a respeito desse padrão.

Em complementaridade, considerando que os consumidores tendem a consumirem de um repertório de marcas dentro de uma mesma categoria, o índice de polarização ( $\phi$ ), também conhecido como medida latente de polarização de lealdade, tem sido considerado para auxiliar na mensuração da lealdade comportamental multimarcas (e.g., Casteran et al., 2019; Corsi et al., 2011; Dawes et al., 2015; Fader & Schmittlein, 1993; Rungie & Laurent, 2012; Trinh et al., 2017). O  $\phi$ , que varia entre zero e um, captura o nível de heterogeneidade das escolhas do consumidor na categoria. Valores de  $\phi$  próximos de zero indicam que todos os consumidores da categoria possuem a mesma propensão para consumir marcas individuais, sinalizando menor lealdade e mais troca de marca (i.e., pura homogeneidade). E valores de  $\phi$  próximos de um indicam que cada consumidor consome apenas uma marca na categoria, sinalizando maior lealdade e menos troca de marca (i.e., pura heterogeneidade) (Fader & Schmittlein, 1993).

O uso de  $\phi$ , em complementariedade aos parâmetros do modelo *NBD-Dirichlet*, tem sido recomendado por ser uma métrica de lealdade que é independente do período, participação de mercado ou qualquer outro fator passível de distorção. E, em conjunto com sua comparabilidade entre categorias, o torna uma medida de lealdade comportamental relevante aos gestores (Casteran et al., 2019; Corsi et al., 2011; Dawes et al., 2015; Driesener et al., 2022).

## **2.2 Padrões de compartilhamento de consumidores – Lei da compra duplicada**

A Lei da compra duplicada, assim como o DJ, parte do pressuposto que os consumidores tendem a consumirem de um repertório de marcas de uma categoria em determinado período e assinala que o consumidor de qualquer marca específica X também compra uma marca concorrente Z, por exemplo, na próxima ocasião de compra e, em ocasiões posteriores, compra X novamente. A troca de X para Z não indicaria, necessariamente, uma alteração na consideração subjacente a qualquer uma das marcas, mas apenas refletiria que o consumidor tende a alternar entre um conjunto de marcas ao longo de várias ocasiões (Colombo & Morrison, 1989; Dawes, 2008, 2016a,



2016b; Ehrenberg, 1988; Ehrenberg & Goodhardt, 1968b; Scriven et al., 2017). Quando agregado esse comportamento ao nível da marca, é revelado um padrão empírico que concerne à extensão em que os consumidores de uma marca também consomem outras marcas concorrentes, denominado Lei da compra duplicada (*Duplication of Purchase – DoP*) (Dawes, 2016a; Scriven et al., 2017; Wilson & Winchester, 2019).

O padrão da compra duplicada evidencia que, quando considerada uma determinada categoria de bens, cada marca que a compõe não apenas compete como, também, compartilha seus consumidores com todas as outras marcas de acordo com o tamanho delas (e.i., penetração da marca). Em outras palavras, as marcas compartilham menos consumidores com marcas menores e mais consumidores com marcas maiores (Dawes, 2008, 2016a, 2016b; Ehrenberg et al., 2004; Trinh & Dawes, 2020).

A análise de DoP descreve os possíveis níveis normais (estimativas teóricas) de sobreposição de consumidores entre as bases de consumidores de marcas concorrentes em determinado período. A partir das estimativas teóricas, é possível identificar se os níveis reais de duplicação entre marcas de um mercado seguem o padrão ou apresentam desvios que indiquem partições/subcategorias (Anesbury et al., 2018b; Colombo et al., 2000; Uncles et al., 1995). O particionamento aponta que grupos de marcas possuem diferenciais e que há uma maior sobreposição de consumidores entre si, resultando em uma competição mais acirrada entre elas e menos com outras marcas da categoria (Anesbury et al., 2022; Dawes, 2016a, 2016b; Scriven et al., 2017).

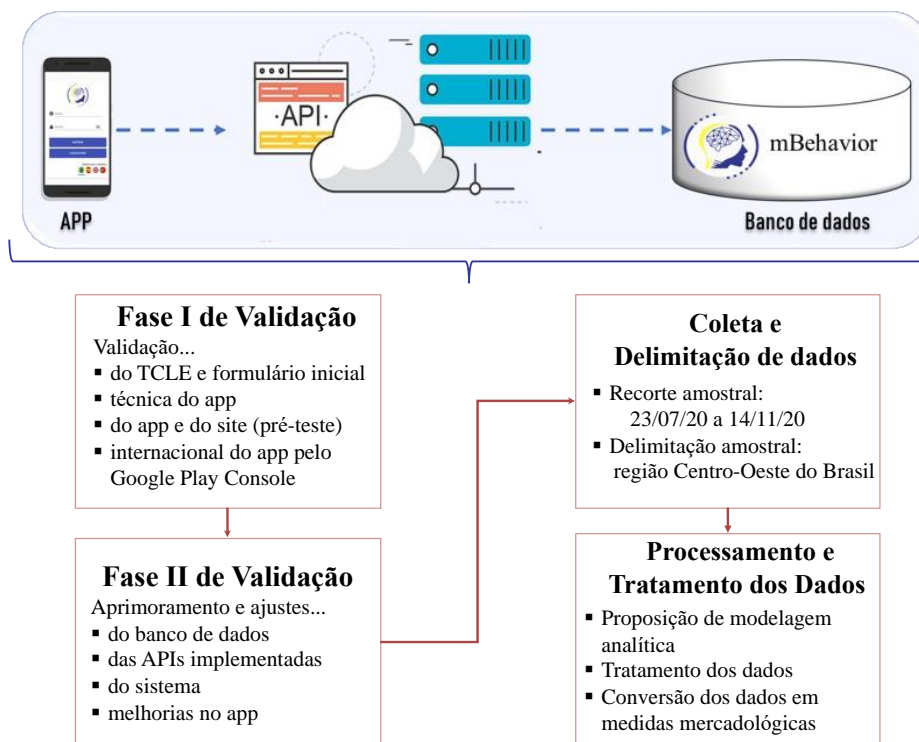
A análise de DoP demonstrou-se robusta e válida ao nível da marca em uma ampla gama de mercados e condições (e.g., de bens de consumo a bens duráveis), apresentando contribuições para o conhecimento de padrões relacionados ao compartilhamento da base de consumidores, partições e estrutura competitiva de mercado (cf. Driesener & Rungie, 2022; Ehrenberg et al., 2004; Scriven et al., 2017; Sharp et al., 2012). Espera-se que no estágio de uso efetivo de marcas de apps também tenda a seguir essa regularidade.

## 2.3 Métodos

Para o alcance dos objetivos propostos, devido à indisponibilidade de painéis de dados longitudinais de uso de aplicativos, foi idealizado como instrumento de coleta de dados um aplicativo mobile de monitoramento (denominado de mBehavior App), tendo como principal funcionalidade o rastreamento anonimizado do comportamento do consumidor mobile em tempo real. Considerando a complexidade do desenvolvimento e o rigor necessário para a validação do instrumento, sua proposta foi transformada em um projeto de pesquisa, denominado “M-Behavior: Entendendo o comportamento do consumidor mobile”. Na Figura 2 é apresentada, de forma esquemática, as etapas que precedem os painéis de dados mencionados/utilizados nos estudos que compõem esta tese: Fases I e II de validação do mBehavior App; coleta e delimitação dos dados; e processamento e tratamento dos dados (para um maior detalhamento do processamento e tratamento dos dados consultar Apêndice A).

**Figura 2**

*Instrumento de coleta de dados – mBehavior App*



Cabe salientar que o desenvolvimento do mBehavior App foi focado na captura das atividades mobile diárias de voluntários de forma discreta, em uma configuração que se implementou os princípios de privacidade por design. Desse modo, os dados somente foram coletados depois que o usuário leu e aceitou o Termo de Livre Consentimento e Esclarecido – TCLE; o nível de detalhamento dos dados foram coletados conforme as permissões aceitas e a versão do app instalada; em ocasiões que o usuário optou, seja por meio de gerenciadores de cachê ou bateria e/ou por remoção do login, interromper a comunicação com o mBehavior App nenhum dado foi transferido para os servidores. Portanto, daqui em diante, ao ser mencionado dias de registros refere-se aos dias de uso efetivo (sequenciado ou não) que os dispositivos se comunicaram com os servidores do mBehavior App.

### **2.3.1 Amostra**

Para a verificação de padrões de lealdade comportamental e compartilhamento da base de consumidores de marcas de apps, examinou-se um subconjunto de dados que contém medições de dispositivos Android de 126 consumidores do Centro-Oeste do Brasil com 28 dias ou mais de registro de atividades de uso de aplicativos, coletados no período de 23 de julho a 14 de novembro de 2020. Dos consumidores, 54,33% eram do sexo feminino, com idade média de 28,42 (dp=10,25). O conjunto de dados resultante inclui um total de 348.362 registros de acessos padronizados a 237 marcas de aplicativos em quatro categorias (Comunicação, Educação, Saúde & Fitness e Social) listadas na Google Play Store, das quais 61,54% possuem estratégias declaradas de monetização (*In-App Purchase e/ou Ads*).

A escolha das categorias foi motivada por elas já estarem presentes no mercado há mais de 10 anos, sendo que duas delas apresentam popularidade estável (Comunicação e Social) e duas que estão em crescente popularidade (Educação e Saúde & Fitness) (Li et al., 2020b), possibilitando uma abrangência de cenários. Uma visão geral das categorias de aplicativos usadas neste estudo pode ser obtida na Tabela 1.

**Tabela 1***Visão geral das categorias de aplicativos consideradas neste estudo*

Categoria de app	Número de marcas de apps	Número de consumidores usando a categoria <sup>a</sup>	Total de acessos aos app por categoria
Comunicação	46	126	242.086
Social	48	123	101.341
Educação	82	74	2.783
Saúde & Fitness	61	68	2.152

*Nota.* <sup>a</sup>N= 126

Cabe acrescentar que todas as análises neste estudo são concebidas em termos de incidência de uso (ocasiões de uso), ou seja, o número de vezes em que uma *marca<sub>j</sub>* foi acessada no período. Essa escolha se justifica devido: i) ao fato de que cada interação do consumidor com app é relevante para o sucesso do app (Al-Nabhani et al., 2022) e permite considerar as trocas entre os apps pelos consumidores; e ii) ao aporte nas generalizações empíricas do modelo NBD-Dirichlet (cf. Driesener & Rungie, 2022; Ehrenberg et al., 2004; Ehrenberg & Goodhardt, 1970).

### **2.3.2 Tratamento e análise dos dados**

Para as análises dos dados foi utilizado o modelo estocástico NBD-Dirichlet (Ehrenberg & Goodhardt, 1970; Goodhardt et al., 1984) que tem sido adotado na área de marketing para analisar padrões de escolha dos consumidores no nível agregado da marca. Ehrenberg et al. (2004) salientam que o propósito da modelagem de Dirichlet não é prever o volume de vendas das marcas individuais, mas, sim, explicar a estrutura de mercado das marcas, como, por exemplo: auditar o desempenho de marcas estabelecidas, prever e avaliar o desempenho de novas marcas, verificar a natureza de mercados desconhecidos, de mercados particionados e de situações dinâmicas de mercado em geral (fornecendo parâmetros teóricos para promoções de preços, publicidade etc.).

Foi utilizado o software Dirichlet (Kearns, 2010) para estimar o modelo. O modelo foi calibrado para cada uma das quatro categorias de aplicativos mobile e as marcas para um período de um mês (detalhes do modelo podem ser consultados no Apêndice B). Foram consideradas as medidas observadas de penetração de uso da marca e categoria, frequência de uso da marca e categoria e market share de uso das marcas (Ehrenberg et al., 2004; Goodhardt et al., 1984).

Ao calibrar o modelo, cada possível uso feito por qualquer consumidor foi implicitamente especificado como uma representação estocástica ou probabilística. Essas probabilidades de uso foram agregadas no modelo para fornecer uma estimativa teórica (previsão) das medidas de desempenho referentes ao tamanho da marca, lealdade comportamental e compartilhamento da base de consumidores.

Embora um considerável corpo de pesquisa sobre a temática tenha sido desenvolvido no contexto de compra de marcas, a fim de investigar essas abordagens no contexto de uso efetivo de marcas, a adaptação das métricas são necessárias para a consideração de dados da incidência de uso de marcas de aplicativos. Considerando a recomendação de Aguinis et al. (2021) de melhores práticas metodológicas para replicações futuras, na Figura 3 são apresentadas a descrição das métricas adaptadas para medir o desempenho de marcas de apps no estágio de uso efetivo.

**Figura 3**

*Descrição das métricas para marcas de aplicativos no estágio de uso efetivo*

Métrica	Descrição
Penetração de uso da categoria	A proporção de consumidores disponíveis que usam a categoria pelo menos uma vez no período especificado. $B = \frac{\text{número de consumidores que acessaram a categoria pelo menos uma vez}}{\text{total de consumidores em potencial}}$
Frequência média de uso da categoria	A taxa média de uso da categoria entre os consumidores da categoria. $W = \frac{\text{número total de acessos a categoria}}{\text{total de consumidores da categoria}}$
Penetração de uso da marca $j$	A proporção de consumidores disponíveis que usam a marca pelo menos uma vez no período especificado. $b = \frac{\text{número de consumidores que acessaram a marca pelo menos uma vez}}{\text{total de consumidores em potencial}}$
Frequência média de uso da marca $j$	A taxa média de uso da marca entre os consumidores da marca. $w = \frac{\text{número total de acessos a marca}_j}{\text{total de consumidores da marca}_j}$
Market share de uso da marca $j$	Total de uso da marca como proporção do total de uso da categoria. $ms = \frac{\text{total de acessos a marca}_j}{\text{total de acesso da categoria}}$
100% leais da marca $j$	A proporção de consumidores da marca que usam apenas essa marca (incluindo consumidores que usam apenas uma vez). $= \frac{\text{número de consumidores que acessaram apenas a marca}_j}{\text{total de consumidores da marca}_j}$
Tamanho médio do repertório de uso	Número médio de marcas usadas pelos consumidores da categoria no período.

Índice de polarização ( $\varphi$ )	<p>Valores de <math>\varphi</math> próximos de zero indicam que todos os consumidores possuem a mesma propensão para usar marcas individuais (<i>i.e.</i>, pura homogeneidade). E valores de <math>\varphi</math> próximos de um indicam que cada consumidor usa apenas uma marca na categoria (<i>i.e.</i>, pura heterogeneidade).</p> $\varphi = \frac{1}{(1 + S)}$ <p>onde <math>S</math> é um parâmetro do modelo de Dirichlet (detalhes do modelo podem ser consultados no Apêndice B); e <math>0 &lt; \varphi &lt; 1</math></p>
Índice de compartilhamento de partição ( $PSI$ )	<p><math>PSI</math> igual a um indica que duas marcas de app compartilham consumidores entre si conforme o esperado, considerando suas respectivas taxas de penetração. <math>PSI</math> menor que um indica que as marcas compartilham menos consumidores do que o esperado. E <math>PSI</math> maior que um indica que as marcas compartilham mais consumidores do que o esperado, segundo Sjoström et al. (2014) uma análise mais aprofundada para conclusões gerenciais deve ser realizada quando marcas apresentam <math>PSI &gt; 1,2</math>.</p> $PSI_{ij} = \frac{S_{ij}}{(D * b_i)}$ <p>onde <math>S_{ij}</math> é a duplicação dos dados de uso da <math>marca_i</math> com a <math>marca_j</math>; <math>D</math> é o coeficiente de duplicação da categoria; e <math>b_i</math> é penetração da <math>marca_i</math>.</p>

Cabe acrescentar que, após o cálculo das medidas observadas usadas para calibrar o modelo, foi observado que uma proporção de marcas de apps eram pequenas tanto em penetração quanto em participação de mercado e incluí-las no modelo poderia gerar vieses devido ao tamanho amostrado e variação excessiva. Dessa forma, foram consideradas para as análises as marcas de apps com Market Share de uso  $\geq 0,7\%$  e penetração de uso  $\geq 1\%$ . As demais marcas de apps foram agregadas, conforme recomendado na literatura, em uma “super marca” intra-categoria (Ehrenberg et al., 2004; Goodhardt et al., 1984; Habel & Lockshin, 2013; Scriven et al., 2017), denominada de “Todas as outras marcas”.

Para determinar se o Dirichlet modelava com precisão o comportamento de uso de aplicativos, foram utilizados testes de adequação estatística propostos na literatura (cf. Driesener et al., 2017) – comparação de médias (AVE%), erro médio absoluto relativo (RAAE), erro médio absoluto percentual (MAPE) e correlação. Os testes são recomendados para a comparação das métricas observadas e teóricas de Dirichlet referente à penetração e frequência média de compra de marcas. Para a penetração os *benchmarks* esperados para Ave%, RAAE, MAPE e correlação são  $\leq 5\%$ ,  $\leq 20\%$ ,  $\leq 20\%$  e  $\geq 0,9$ , respectivamente. E para a frequência de média de compra os valores de referência são  $\leq 10\%$ ,  $\leq 20\%$ ,  $\leq 20\%$  e  $\geq 0,6$ , respectivamente. Driesener et al. (2017) propõem que um bom ajuste é alcançado se, pelo menos, cinco dos oito testes forem atendidos para compras de marcas em categorias de FMCG. No presente estudo, o quantitativo de ajustes atendidos variou entre as categorias: Comunicação 3/8; Educação 1/8; Saúde & Fitness 3/8; e

Social 4/8. Desse modo, considerando o recorte amostral, as categorias de aplicativos investigadas não foram bem modeladas pelo Dirichlet no estágio de uso efetivo, ou seja, os resultados se desviam consideravelmente da previsão teórica quando utilizados os ajustes de *benchmarks* do contexto de compra em mercado de FMCG.

Contudo, estudiosos (Bhattacharya, 1997; Driesener & Rungie, 2022; Ehrenberg et al., 2004; Kennedy et al., 2014; Scriven et al., 2017; Sharp, 2014) sugerem que, mesmo quando não há bons ajustes estatísticos para alguma categoria de produto, os valores previstos de Dirichlet são parâmetros teóricos úteis para interpretar a estrutura do mercado investigado e fornecer insights de direcionamentos futuros. Assim, os resultados deste estudo podem fornecer parâmetros comparativos para novos estudos no contexto de uso efetivo de marcas. No próximo tópico serão apresentados os resultados considerando o exposto como ponderação para a interpretação dos achados.

## 2.4 Resultados

Na Tabela 2 são apresentadas as medidas de desempenho das marcas de apps por categoria referentes ao tamanho da marca (market share e penetração) e lealdade comportamental, dado a amostra investigada em um período de 30 dias. Observa-se que, entre as categorias investigadas, a categoria de Comunicação foi a que apresentou: maior participação de uso (69,5%); maior penetração de uso (100%); maior frequência média de uso no período por consumidor (1921,3); maior repertório médio de marcas de apps relativo (4,6); não possui consumidores 100% leais a uma marca; e o menor índice de polarização ( $\phi=0,11$ ). Em contrapartida, a categoria de Saúde & Fitness foi a que exibiu: menor participação de uso (0,6%); menor penetração de uso (54%); menor repertório médio de marcas de apps relativo (1,5); a maior proporção média de consumidores 100% leais por marca (32,3%); e o maior índice de polarização ( $\phi=0,79$ ).

**Tabela 2***Medidas de desempenho de mercado*

	Market Share (%)	Penetração (%)	Medidas relacionadas à lealdade/mês			
			Frequência média de uso	100% Leais	$\varphi$	Tamanho médio do repertório
<b>Categoria de Comunicação</b>	<b>69,5</b>	<b>100</b>	<b>1921,3</b>		<b>0,11</b>	<b>4,6<sup>#</sup></b>
WhatsApp	78,8	97,6	1551,1	0		
Google Chrome	12,1	96,8	239,9	0		
Todas as outras marcas (41)	3,1	88,1	68,1	0		
Gmail	2,9	92,1	60,4	0		
Messenger	2,0	74,6	50,6	0		
WhatsApp Business	1,1	7,9	271,0	0		
<i>Marca Média</i>	<i>16,7</i>	<i>76,2</i>	<i>373,5</i>	<i>0</i>		
<i>Correlação de Dirichlet</i>	<i>-</i>	<i>0,66*</i>	<i>0,99***</i>			
<b>Categoria Social</b>	<b>29,1</b>	<b>97,6</b>	<b>823,9</b>		<b>0,32</b>	<b>3,1<sup>#</sup></b>
Facebook	46,3	83,3	446,7	3,8		
Instagram	45,4	88,9	410,7	3,6		
Twitter	3,5	27,0	104,6	2,9		
TikTok	2,2	39,7	45,6	0,0		
Facebook Lite	1,1	5,6	152,1	0,0		
Snapchat	0,8	15,9	41,6	0,0		
Todas as outras marcas (42)	0,7	38,9	14,5	4,1		
<i>Marca Média</i>	<i>14,3</i>	<i>42,7</i>	<i>173,7</i>	<i>2,1</i>		
<i>Correlação de Dirichlet</i>		<i>0,93***</i>	<i>0,97***</i>	<i>0,57*</i>		
<b>Categoria de Educação</b>	<b>0,8</b>	<b>58,7</b>	<b>37,6</b>		<b>0,56</b>	<b>1,9<sup>#</sup></b>
Google Classroom	37,9	19,0	43,9	16,7		
Todas as outras marcas (76)	23,9	34,9	15,1	27,3		
Moodle	20,6	19,8	22,9	20,0		
Sou UFMS	5,9	23,0	5,7	17,2		
Duolingo	4,6	5,6	18,1	14,3		
Passei Direto	4,5	4,8	20,7	16,7		
12min - Resumos de Livros	2,7	4,0	15,0	40,0		
<i>Marca Média</i>	<i>14,3</i>	<i>15,9</i>	<i>20,2</i>	<i>21,7</i>		
<i>Correlação de Dirichlet</i>		<i>0,68**</i>	<i>0,77**</i>	<i>0,35</i>		
<b>Categoria de Saúde &amp; Fitness</b>	<b>0,6</b>	<b>54,0</b>	<b>31,6</b>		<b>0,79</b>	<b>1,5<sup>#</sup></b>
Todas as outras marcas (51)	44,3	28,6	26,5	47,2		
Strava: Correr, Pedalar e Monitorar o Treinamento	14,5	8,7	28,5	63,6		
Samsung Health	10,4	10,3	17,2	61,5		
Guardiões da Saúde	9,3	6,3	25,0	12,5		



Calendário Menstrual, Período Fértil e Ovulação	6,6	7,9	14,3	40,0
Meu Calendário Menstrual Flo. Ovulação e Gravidez	3,8	7,1	9,0	55,6
Bodytech	3,3	1,6	35,0	0,0
Nike Training Club – Treinos e planos fitness	2,4	1,6	26,0	0,0
Queima Diária	2,0	1,6	21,5	50,0
Mi Fit	1,9	3,2	10,3	25,0
Adidas Running by Runtastic: Correr e Fitness	1,4	1,6	15,5	0,0
<i>Marca Média</i>	<i>9,1</i>	<i>7,1</i>	<i>20,8</i>	<i>32,3</i>
<i>Correlação de Dirichlet</i>		<i>0,97***</i>	<i>0,30</i>	<i>0,34</i>

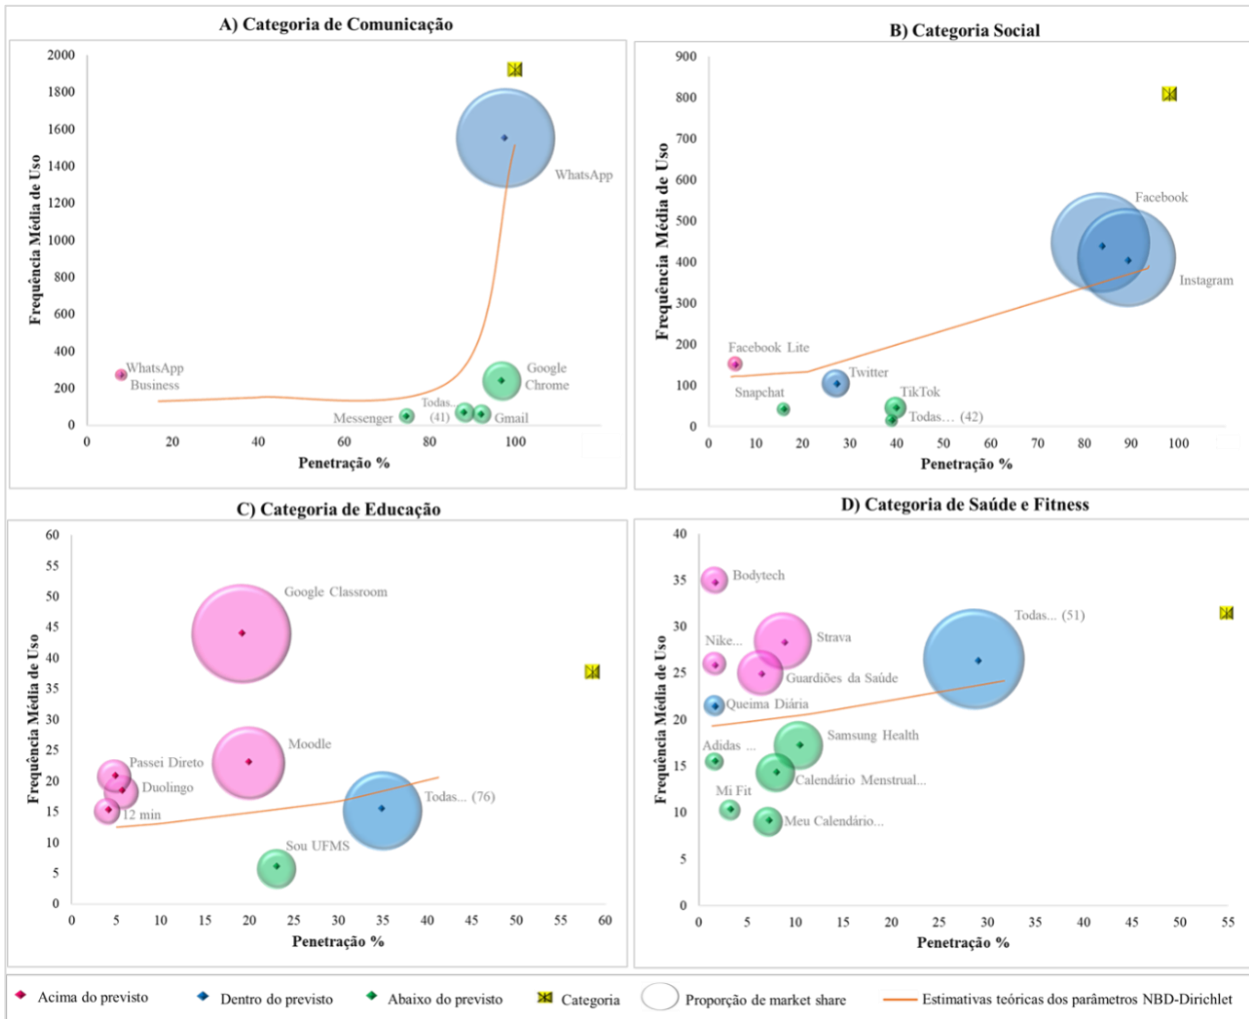
Nota. \*\*\* p<0,001; \*\* p<0,05; \* p<0,1; #repertório médio observado é igual ao repertório médio previsto

#### **2.4.1 Padrão do duplo risco aplicado a marcas de aplicativos**

Na Figura 4 é apresentada a comparação entre os valores observados e as estimativas teóricas dos parâmetros de Dirichlet para a análise do padrão do duplo risco (DJ) para as quatro categorias investigadas. A categoria de comunicação (gráfico A, Figura 4) apresentou moderado ajuste, contudo, quando plotado o gráfico, é possível observar que, dadas as características gerais da categoria referente a penetração e frequência média de uso, a linha teórica de Dirichlet de DJ previu a tendência de desempenho das marcas. Considerando o benchmark de 10% de desvio (Kahn *et al.*, 1988), a marca de maior tamanho (WhatsApp) foi a única com valores dentro do esperado, revelando que, apesar da sua alta participação de mercado, penetração e frequência de uso, ela não apresenta excesso de lealdade. A segunda maior marca (Google Chrome, representada em verde) apresentou penetração próxima ao esperado, porém o modelo previu níveis de lealdade um pouco maior do observado (12,1%). As demais marcas em verde apresentam penetração de uso consideravelmente mais alta e frequência de uso consideravelmente mais baixa do que o previsto. A menor marca dentro da categoria que atendeu aos parâmetros da análise (WhatsApp Business, representado em rosa) apresentou uma baixa penetração, mas possui a segunda maior taxa média de uso, revelando indícios de marca de nicho.

Figura 4

Double Jeopardy e Benchmark Dirichlet



*Nota.* Os pontos rosas, azuis e verdes representam os dados observados. A linha laranja representa as estimativas teóricas dos parâmetros do NBD-Dirichlet. Quanto maior a distância entre os pontos e a linha, maiores serão os desvios da expectativa. Pontos rosas e verdes são as marcas que se desviam mais de 10% dos valores teóricos. As marcas com valores dentro do esperado são as azuis. O quadrado amarelo representa os dados observados da categoria; e os círculos sombreados correspondem a proporção de market share da marca.

A categoria de Social (gráfico B, Figura 4) foi a que apresentou melhor ajuste com a linha teórica Dirichlet de DJ – as três maiores marcas (Facebook, Instagram e Twitter) apresentam penetração e frequência de uso dentro do esperado. A terceira marca com maior frequência média de uso (Facebook Lite, em rosa) apresentou baixo market share e penetração uso quando comparada com os demais apps da categoria, remetendo-a ao posicionamento de nicho. Já as

demais marcas, representadas em verde no gráfico, revelaram taxas de penetração mais altas e frequência de uso mais baixa do que previsto.

A categoria de Educação foi a que apresentou o menor ajuste ao modelo. Dos seis apps identificados que atendiam aos parâmetros da análise, três são aplicativos relacionados ao ensino superior e um relacionado ao ensino de forma remota (independentemente do nível de ensino). Como pode ser observado no gráfico C (Figura 4), o app com maior market share e com frequência de uso acima da média da categoria (Google Classroom, em rosa), apresentou penetração consideravelmente menor do que o valor esperado dado às outras medidas. Por outro lado, a segunda marca com melhor desempenho e que apresentou desempenho dentro do esperado foi a super marca (Todas as outras marcas) que agregou 76 marcas apps pequenas, conforme critério adotado para ajuste do modelo.

A categoria de Saúde & Fitness (gráfico D, Figura 4), por ser a menor categoria em penetração e frequência de uso, a super marca (agregado de 51 marcas de apps pequenas), foi a que apareceu como tendo as maiores medidas de desempenho e estando dentro dos valores previstos. Entre as marcas que apresentaram penetração menor e frequência de uso maior do que o previsto (em rosa), a maioria (75%) são marcas de apps de treino e uma marca de apps local (Guardiões da Saúde) de cunho científico. Por outro lado, as marcas que apresentaram penetração maior e frequência de uso menor do que o previsto (em verde), em sua maioria (80%), são marcas de aplicativo voltadas para o monitoramento de rotina diária.

#### ***2.4.2 Compartilhamento de consumidores entre marcas de aplicativos***

O padrão da compra de duplicação (DoP) mede a proporção de compartilhamento da base de consumidores entre as marcas de apps de uma categoria (no recorte temporal investigado). Os valores nas tabelas de DoP (ver Tabela 3 e Tabelas 6 a 8 do Apêndice C) devem ser interpretados como a proporção de consumidores das marcas de apps listadas na primeira coluna (da maior para a menor em penetração) que também usaram cada uma das outras marcas de apps listadas na linha superior. Por exemplo, a Tabela 3 apresenta as taxas de duplicação para a categoria de Social: observa-se que o Instagram compartilha 86,6% dos seus consumidores com o Facebook, 42,9%

com o Tiktok, 40,2% com todas as outras marcas, 29,5% com o Twitter, 17% com o Snapchat e 6,3% com o Facebook Lite.

**Tabela 3**

*Duplicação para marcas de aplicativo da categoria Social*

Consumidor de ...	Penetração (%)	% que também usa (SPI)						
		Instagram	Facebook	TikTok	Todas as outras marcas (42)	Twitter	Snapchat	Facebook Lite
Instagram	88,9		86,6 (0,9)	42,9 (1,0)	40,2 (0,9)	29,5 (1,0)	17 (1,0)	6,3 (1,0)
Facebook	83,3	92,4 (0,9)		42,9 (1,0)	41,9 (1,0)	25,7 (0,9)	16,2 (0,9)	4,8 (0,8)
TikTok	39,7	96 (1,0)	90 (1,0)		48 (1,1)	30 (1,0)	18 (1,0)	8 (1,3)
Todas as outras marcas (42)	38,9	91,8 (0,9)	89,8 (1,0)	49 (1,1)		30,6 (1,0)	18,4 (1,0)	6,1 (1,0)
Twitter	27,0	97,1 (1,0)	79,4 (0,9)	44,1 (1,0)	44,1 (1,0)		23,5 (1,3)	5,9 (1,0)
Snapchat	15,9	95 (1,0)	85 (0,9)	45 (1,0)	45 (1,0)	40 (1,3)		15 (2,4)
Facebook Lite	5,6	100 (1,0)	71,4 (0,8)	57,1 (1,3)	42,9 (1,0)	28,6 (1,0)	42,9 (2,4)	
<i>Duplicação média</i>	42,7	95,4	83,7	46,8	43,7	30,7	22,7	7,7
<i>Duplicação média esperada</i>		98,2	92,1	43,9	43,0	29,8	17,5	6,1

Correlação (observada x esperada) 0,99 (p=0,000)

*Nota.* Período de análise = um mês; (SPI) = Índice de compartilhamento de partição; Desvios gerenciais significativos são destacados em cinza escuro (> 1,2)

A análise da DoP aponta que, no mercado mobile app, aplicativos de uma mesma marca mãe com funcionalidades fins iguais também tendem a compartilhar seus consumidores. Por exemplo, o Facebook e o Facebook Lite que compartilharam entre si 6,3% e 100% dos seus consumidores, respectivamente. E o DoP demonstrou que esse compartilhamento é normal, considerando a amostragem.

O índice de compartilhamento de partição (PSI) (valores entre parênteses nas tabelas de duplicação) foi utilizado para determinar se há compartilhamento da base de consumidores menor, maior ou igual ao esperado. O PSI igual a 1,0 revela que as marcas de apps compartilham seus consumidores conforme o previsto pelo modelo, por exemplo, WhatsApp e Google Chrome (apêndie C, Tabela 6). A categoria de comunicação (apêndice C, Tabela 6) foi a que o modelo melhor previu o compartilhamento de consumidores, não apresentando nenhum desvio gerencial.

Na categoria de Educação (apêndice C, Tabela 8) foi constatado um compartilhamento da base de consumidores do app Sou UFMS com o app Moodle e o Passei Direto, de aproximadamente de 50% (PSI=1,5) e 100% (PSI=2,0) respectivamente, maior que o previsto. Esses resultados apontam para um possível particionamento de mercado de marcas que atendem a uma subcategoria “ensino superior”. Nesse caso em específico, os apps pertencentes a essa partição apresentam características de bens complementares.

A categoria de Saúde & Fitness (apêndice C, Tabela 8) foi a que apresentou os maiores desvios da estimativa teórica. Levando em consideração que a categoria possui baixa penetração, altas taxas de consumidores 100% leais, repertório médio relativo pequeno e, dadas as características dos apps, ao observar os PSI das marcas que a compõem é possível supor que consumidores mais pesados da categoria tendem a formarem repertórios com mais apps complementares do que com apps substitutos.

Nas categorias de Educação e Saúde & Fitness foram constatados desvios significativos do previsto para o compartilhamento de consumidores entre algumas marcas de apps e as super marcas (Todas as outras marcas), contudo compreensível devido à agregação de mais de 50 marcas de apps em cada.

Em geral, o compartilhamento de consumidores está alinhado com a proporção de consumidores que usaram as marcas de apps pelo menos uma vez nas categorias investigadas. Todas as categorias apresentaram bom ajuste ao modelo, com correlação acima de  $r=0,90$  entre as duplicações médias observadas e esperadas. A probabilidade de consumidores usarem distintas combinações de marcas de aplicativos intra-categoria pode ser prevista quantitativamente com base na prevalência populacional dos usos constituintes.

## **2.5 Discussão dos resultados**

Os resultados deste estudo fornecem uma nova singular sobre os padrões de uso efetivo de marcas no contexto do mercado mobile apps, focalizando especificamente no desempenho de marcas em diferentes categorias. Em primeiro lugar, evidenciou-se que os consumidores apresentam lealdade dividida, manifestada como comportamento de consumo de repertório de marcas de apps (Driesener & Rungie, 2022; Ehrenberg et al., 2004; Trinh et al., 2017).

Os resultados corroboram com a presunção do modelo de Dirichlet de que os consumidores intra-categoria consomem um pequeno quantitativo das marcas disponíveis (Driesener & Rungie, 2022; Scriven et al., 2017; Sharp et al., 2012). Cabe relatar que a amplitude do tamanho repertório médio de uso de marcas (1,5 a 4,6) no mercado de apps variou um pouco mais do que o tamanho médio de compra de marcas relatado em mercados de compra rotineira (2 a 3) (Banelis et al., 2013; Dawes, 2008). Contudo, conforme alegado por Trinh (2014), desvios consideráveis no tamanho do repertório médio podem ocorrer devido a consumidores pesados da categoria.

A lei DJ afirma que o tamanho da marca (market share e penetração) e a frequência de média de compra variam na mesma direção. Porém, que a frequência de média de compra recebida varia pouco entre marcas grandes e pequenas de uma mesma categoria (Dawes et al., 2017; Ehrenberg et al., 2004; Graham et al., 2017; Phua et al., 2020). Em uma perspectiva geral, observou-se que as quatro categorias de apps apresentam indícios do padrão de DJ, mesmo com os desvios da linha teórica. Isto é, as marcas de apps com menores participação de uso tendem a receberem menores penetração e frequência média de uso.

Contudo, cabe ressaltar que no mercado de mobile apps foi identificada uma considerável variação na frequência média de uso intra-categoria, o que culminou em desvios de DJ, revelando tendências de marcas de nicho e de mudança de ritmo, que decorrem normalmente de aspectos específicos da marca, sazonalidade, marketing ou outros fatores contextuais (Kahn et al., 1988; Scriven et al., 2017; Sharp et al., 2012). A categoria de Educação, por exemplo, foi a que apresentou o menor ajuste ao modelo, podendo ser uma das possíveis razões dos desvios devido às mudanças causadas pela pandemia da Covid-19 que modificou a forma de interação dos indivíduos com o ensino (*e.g.*, medidas emergenciais de ensino remoto), apresentando um aumento de cerca de 45% no nível de downloads comparado ao período pré-pandêmico (AppsFlyer & App Annie, 2021).

Em relação ao compartilhamento da base de consumidores, os resultados demonstraram a presença de padrões de duplicação de consumo de marcas de apps. Esses achados são consistentes com a lei de DoP, em que a proporção de consumidores que uma marca compartilha com outras marcas está em linha com a penetração dessas marcas (Anesbury et al., 2018a; Dawes, 2008; Trinh & Dawes, 2020). Contudo, observou-se alguns desvios revelando tendências de subcategorias (partições) que precisariam ser melhores investigadas.

Esses desvios foram mais expressivos para as categorias de Educação e Saúde & Fitness, apontando indícios de uma parcela das marcas apresentarem características de complementares, que corroboram com o encontrado por Wang e Zheng (2020). Investigando o uso de apps de Social, os autores descobriram que, na maioria das vezes, os apps que satisfazem as necessidades psicológicas, diferentes ou semelhantes dos consumidores apresentam características de complementares em vez de substitutos uns dos outros. E que, quanto maior a gama de outros apps um determinado app for complementar, o app é relativamente mais competitivo.

Ao considerar a dinâmica competitiva em uma perspectiva macro (entre categorias), os valores da métrica de penetração foram próximos ao encontrados por Li et al. (2020b), exceto para categoria de educação que foi consideravelmente maior, corroborando, mesmo em um contexto diferente, que as categorias diferem em grau de popularidade – Comunicação e Social (popularidade estável); e Educação e Saúde & Fitness (crescente popularidade).

Considerando a medida latente de polarização de lealdade ( $\varphi$ ), os resultados avançam e complementam esse estudo (Li et al., 2020b), revelando que nas categorias com popularidade estável os consumidores possuem propensão similar para consumir apps diversos (sinalizando menor lealdade e mais troca de marca); enquanto nas categorias com crescente popularidade, os consumidores possuem propensão a consumir apps específicos (sinalizando maior lealdade e menos troca de marca) (Driesener et al., 2022; Fader & Schmittlein, 1993).

## **2.6 Considerações Finais**

No geral, este estudo estendeu as descobertas sobre o comportamento de compra de marcas para o nível do comportamento de uso efetivo de marcas com base na abordagem de marketing baseado em evidências, mais especificamente ao realizar uma replicação de generalização e extensão, modificando aspectos do desenho de pesquisa e contexto, como: a modificação das medidas de mensuração, a extensão para o contexto mobile (uso de marcas de aplicativos) e dados de um mercado emergente ainda não investigado (Brasil).

Ao fazer tais modificações, elucidou-se que os resultados revelam que os padrões de desempenho de marcas de apps no estágio de uso efetivo não diferem substancialmente, em aspectos gerais, dos padrões DJ e DoP encontrados para marcas de outras categorias de bens no

contexto de compra. Os resultados corroboram achados anteriores e estendem para o contexto de uso efetivo a premissa de que o consumo de repertório de marcas pelos consumidores é previsível intra-categoria.

O estudo oferece evidências iniciais de que, no contexto de aplicativos, considerando o estágio de uso efetivo da marca, marcas menores são duplamente penalizadas (conforme previsto pelo DJ). Evidenciou-se, também, a existência de padrões de compartilhamento de consumidores entre marcas intra-categoria em linha com as suas penetrações de uso. Além disso, verificou-se que, sob certas condições, os consumidores consomem os apps intra-categoria como produtos complementares. Assim, os resultados mostram que o modelo NBD-Dirichlet pode ser usado como uma estrutura básica para o entendimento de padrões de desempenho de marcas de aplicativos além do contexto da loja de apps. Essas descobertas têm implicações teóricas úteis ao estabelecer novas condições em que padrões de lealdade comportamental do consumidor e de compartilhamento das bases de consumidores se sustentam.

Os resultados aqui encontrados podem fornecer aos desenvolvedores e gestores de marcas de apps insights que auxiliem a tomar decisões informadas de comunicação e posicionamento, ao aplicarem tais benchmarks a dados comportamentais (Ehrenberg et al., 2004). Por exemplo, os resultados apontam indícios de que, com o intuito de aumentar o comportamento de uso da marca do app, os níveis de penetração de uso devem ser aumentados. Por conseguinte, isso levaria a aumentos na lealdade do consumidor pela marca.

Este estudo também identificou possíveis partições de mercado, mostrando maior (ou menor) compartilhamento entre algumas marcas de apps do que o esperado. Desvios, quando observados e compreendidos, podem levar a insights gerenciais. A subcategoria identificada na categoria de Educação, por exemplo, tendeu a indicar marcas que se complementam e poderiam se beneficiar de estratégias de cooperação ganha-ganha. Os gestores de marcas de apps poderiam melhorar a competitividade, adicionando em seus designs de apps recursos de cooperação com as outras marcas das quais compartilham mais a sua base de usuários. Essa estratégia também poderia contribuir para uma maior probabilidade de que potenciais consumidores fossem expostos à marca.

Ao demonstrar que os padrões de DJ e DoP são válidos para marcas de apps das categorias de Comunicação, Social, Educação e Saúde & Fitness, não somente os desenvolvedores e gestores de marcas de app podem se beneficiar ao vislumbrar um panorama da estrutura competitiva do



mercado, mas, também, atores de outras instâncias do ecossistema mobile. Por exemplo, para empresas que estejam almejando integrar um app como uma estratégia de extensão de marca ou como uma oferta digital, o panorama do mercado demonstrou indícios que escolher uma categoria que possui menores penetração de uso poderia resultar em uma maior probabilidade de crescimento da marca (Li et al., 2020b).

Apesar dos achados deste estudo ele não está isento de limitações, indicando, assim, rumos para pesquisas futuras. Embora o estudo tenha estendido generalizações empíricas para o uso efetivo de marcas, considerando dados de marcas de quatro categorias de aplicativos em um mercado emergente (Brasil), replicações diferenciadas adicionais se fazem necessárias para determinar se esses padrões encontrados são válidos em outras categorias de apps e/ou em outros mercados. Estudos futuros poderiam fornecer contribuições adicionais investigando as razões para os desvios teóricos encontrados para DJ e DoP.

Não obstante, os resultados deste estudo fornecem insights relevantes de forma agregada no nível da marca, mas informações no nível do consumidor seriam particularmente importantes. Por fim, estudos futuros também poderiam avançar as descobertas deste estudo, investigando possíveis antecedentes que impulsionam esses padrões de desempenho de marcas de apps no estágio de uso efetivo.

### **3 O efeito da força da marca no desempenho de marcas de apps - Estudo 2**

No Estudo 1 evidenciou-se, em geral, que os padrões de desempenho de marcas no contexto de compra se estendem ao contexto de uso efetivo de marcas no mercado de mobile apps, mais especificamente, em relação às métricas competitivas de marcas de apps – tamanho da marca (penetração e market share de uso) e lealdade comportamental. Uma vez conhecido o panorama competitivo das marcas neste mercado, seria interessante avançar o conhecimento sobre o que impulsiona os resultados de desempenho das marcas, pois, segundo Porto e Oliveira-Castro (2015), os indicadores de desempenho de marcas carecem de uma explicação do porquê ocorrem para auxiliar no planejamento estratégico mercadológico.

Estudiosos comportamentais (e.g., Oliveira-Castro et al., 2008; Porto & Lima, 2015; Porto & Oliveira-Castro, 2015) têm evidenciado que a força da marca pode explicar, em parte, o desempenho competitivo das marcas (e.g., market share e penetração) no contexto de compra da marca, evidenciando, também, que a influência desse preditor pode variar conforme a categoria do bem (possível efeito de moderação).

Esses estudiosos têm se apoiado na abordagem da perspectiva comportamental – pautada em princípios da economia comportamental operante e da área de marketing –, que tem oferecido um arcabouço teórico-metodológico robusto sobre a ligação entre os comportamentos da empresa e do consumidor, demonstrando que o comportamento de ambas as partes se integra em redes que se influenciam mutuamente, uma vez que as ofertas de bens (marcas) das empresas são estímulos discriminativos programados para o comportamento do consumidor, condicionando esse comportamento a retribuições à empresa (cf. Foxall et al., 2021; Porto & Foxall, 2019).

Essa abordagem poderia ajudar no fechamento de lacunas em torno do desempenho de marcas de apps, uma vez que pouco se sabia (até a realização do Estudo 1) sobre a dinâmica competitiva de marcas de apps, além do âmbito das lojas de apps (ponto de distribuição), com base em dados reais. Logo, pesquisas, e consequentemente conhecimento, sobre os efeitos de estratégias de branding também são limitadas (Tang, 2019).

Estudiosos mercadológicos (Gera et al., 2020; Stocchi et al., 2021; Tang, 2019), com base em extensas revisões de literatura, evidenciam que suposições robustas sobre as influências do valor intangível da marca nos resultados de marcas no mercado mobile app ainda não são

suportadas na literatura de marketing. Eles explicam que, em parte, isso se deve ao fato de a maioria dos estudos já desenvolvidos terem se concentrado em aspectos de branding sem considerar o contexto competitivo das marcas de apps e/ou os diferentes estágios de interação consumidor-marca. Dito isso, emergem duas perguntas de pesquisa: qual o efeito da força da marca no desempenho de marcas de apps nos estágios de adoção e de uso efetivo de marcas de apps? E esse efeito varia de acordo com a categoria do app?

Em complementaridade, partiu-se do pressuposto que é reconhecido o papel expressivo dos atores intermediários do ecossistema mobile (lojas de apps – ponto de distribuição) (Finkelstein et al., 2017; Tavalaei & Cennamo, 2021), mas que ainda é preambular a consideração do seu potencial como fonte de dados dos diferentes elos (e.g., marca – ponto de distribuição – consumidor) para a medição e acompanhamento do desempenho das marcas de apps em relação aos aspectos de *branding* (Gokgoz et al., 2021; Stocchi et al., 2021). No presente estudo, visando contribuir para esse gap, considerou-se o potencial dos metadados disponíveis nas lojas de apps para a proposição de uma métrica de força da marca com maior abrangência do contexto competitivo das marcas de apps.

Assim, diante do exposto, este estudo tem como objetivo **analisar o impacto da força da marca no desempenho de marcas de aplicativos nos estágios de adoção e uso efetivo pelo consumidor, testando moderação da categoria do app.**

No próximo subtópico é apresentado o referencial teórico, contextualizando a métrica de força da marca pela abordagem analítico-comportamental, argumentando a relevância da consideração de medidas que capturem a competitividade entre as marcas pela perspectiva da demanda. Em seguida, os métodos de pesquisa são apresentados, abarcando a proposição do indicador de força da marca. Por conseguinte, os resultados são apresentados para cada estágio de interação consumidor-marca, seguidos da discussão e contribuições dos achados. Por fim, as limitações e sugestões de pesquisas futuras são desenvolvidas.

### **3.1 Força da marca pela abordagem analítico-comportamental**

A força da marca, estreitamente relacionada ao Brand Equity, é o valor que uma marca carrega. Considerada uma métrica multidimensional, ela consiste em uma resposta avaliativa ou

comportamental a uma marca por seus consumidores/stakeholder, podendo ser medida de várias maneiras (ISO 20671, 2021). Na perspectiva da demanda, o conteúdo dessa resposta seria o nível de conhecimento ou experiência do consumidor (Keller, 1993, 2021).

Pela perspectiva comportamental, atributos da marca (tangíveis/intangíveis) são interpretados como eventos de reforço (ou punição) programados e controlados por gestores, uma vez que gestores de marketing direcionam esforços em estratégias mercadológicas e inovativas para modificar e moldar as propriedades reforçadoras de seus bens/marcas para deixá-las mais atraentes e entregar maior valor para o consumidor. Contudo, essas ações podem ou não funcionar, motivo pelo qual são consideradas como programadas em vez de reais (Foxall, 1992; Foxall et al., 2004; Oliveira-Castro et al., 2005b; Oliveira-Castro et al., 2008).

Nessa perspectiva, segundo Porto et al. (2022), a força da marca pode ser interpretada como a magnitude dos reforços informativos programados pelos gestores aos consumidores. Esses reforços são consequências sociais programadas – indiretas e simbólicas (feedbacks sociais como status social, prestígio ou aceitação) – associadas ao comportamento de consumo da marca, que, por sua vez, motivarão a taxa de ocorrência de comportamentos semelhantes no futuro (Foxall, 2015; Foxall et al., 2021).

Oliveira-Castro et al. (2008) propuseram um construto de força da marca unindo as métricas de familiaridade (conhecimento) e qualidade percebida das marcas (MCQ). Segundo os autores, a consideração dessas duas medidas se justifica com base em revisão da literatura que apontou que, apesar de não haver um consenso claro sobre as dimensões do valor da marca com base no consumidor, a maioria dos estudos empíricos apresentavam indícios de concordar com a relevância e consideração das métricas de conhecimento e qualidade percebida da marca. Os resultados de estudos recentes (Porto, 2018, 2019), considerando seis métricas para medir o valor da marca com base no consumidor, corroboram a suposição de Oliveira-Castro et al. (2008) ao evidenciarem que essas duas métricas resumem o valor da marca.

Com base na abordagem da perspectiva comportamental, a pressuposição é que, se a maioria dos membros do sistema social atestam que uma determinada marca é de alta qualidade e bem conhecida, maior seria a probabilidade de que o consumo dessa marca seja seguido por reforço social do que se a marca for considerada de baixa qualidade e pouco conhecida (Foxall, 2004; Oliveira-Castro et al., 2008; Oliveira-Castro et al., 2016). Contudo, mesmo que um indivíduo possa

identificar potenciais fontes de reforço social, a depender do contexto de consumo, isso pode ter pouco ou nenhum efeito (Oliveira-Castro et al., 2008).

O construto MCQ, proposto por Oliveira-Castro et al. (2008), é medido por meio de questionário simples, composto por duas perguntas (em escala tipo *Likert*), que capta a percepção de consumidores sobre a magnitude da familiaridade e magnitude da qualidade de marcas de diferentes categorias de bens. Esse tipo de procedimento tem sido interpretado como uma sondagem de contingências sociais programadas relacionadas à escolha de diferentes marcas que derivam de ações e reações de outros membros do sistema social em relação ao desempenho do indivíduo como consumidor, resultando, assim, em uma medida de força da marca com base em abordagem teórica consistente.

Estudiosos comportamentais (Foxall et al., 2021) reconhecem as dificuldades associadas à obtenção de medidas mais precisas e confiáveis em ambientes sociais. Porém advertem que as medidas de magnitude de reforço informativo, devido decorrerem da aplicação de questionários, devem ser interpretadas com cautela. Esses estudiosos lançam luz a novas possibilidades que estão surgindo com o advento do mundo digital e a expansão das transações online cada vez mais onipresentes, que apresentam grande potencial aos analistas do comportamento e cientistas de marketing de obterem medidas úteis e significativas das respostas dos consumidores, devido à coleta de dados mais rica em detalhes que se assemelham a configurações experimentais.

Nesse direcionamento, considerando o contexto do mercado de apps, os consumidores avaliam a qualidade das marcas constantemente. E as lojas de apps disponibilizam-nas juntamente com outras informações que evidenciam o quão conhecida é a marca. Leva-se a acreditar que metadados provenientes de lojas de apps poderiam resultar em uma medida de força da marca equivalente à proposta por Oliveira-Castro et al. (2008), proporcionando uma maior abrangência do contexto competitivo da marca.

Neste direcionamento, ao considerar uma métrica de força da marca, elaborada a partir de metadados de lojas de apps, capaz de comparar várias marcas de apps no nível de análise da marca possibilitaria estabelecer o ranking de marcas intra-categoria e realizar um teste de mercado com métrica desenvolvida por estudiosos (Porto, 2018).

Entidades reguladoras orientam que, para um melhor entendimento do impacto da força da marca no desempenho da marca, a investigação deve ser considerada como um teste de mercado,

uma vez que permite comparar a competitividade entre marcas e obter parâmetros para o estabelecimento de metas ou objetivos de marketing mais realistas (ISO 20671, 2021).

Oliveira-Castro et al. (2008), ao examinarem a relação entre a força da marca e o desempenho da marca, constataram que aumentos no score de força da marca estavam relacionados a aumentos significativos no indicador de desempenho da marca, bem como o peso da influência da força da marca, no desempenho de marcas, varia expressivamente entre as categorias de bens, revelando que, para a maior parcela, a relação foi positiva e significativa.

O estudo que investigou os preditores do desempenho de marcas próprias de supermercado e marcas de fabricantes, em diferentes categorias de bens, constatou que a força da marca é o principal preditor do market share de marcas de fabricantes (Porto & Silva, 2014).

Estudiosos (Porto & Lima, 2015) relatam que o impacto da força da marca varia a depender do indicador de desempenho competitivo considerado, revelando que os resultados para diferentes indicadores de desempenho (e.g., penetração e market share) apresentam formato de influência similar (exponencial e não-linear), diferindo apenas no peso de seu efeito para cada marca.

Em síntese, esses estudos comportamentais baseados em dados de compras de bens de consumo de movimento rápido (FMCG) apontam que: a força da marca prevê o desempenho competitivo de marcas; e o efeito tende a ser positivo (Oliveira-Castro et al., 2008; Porto & Carvalho, 2015; Porto & Lima, 2015; Porto & Melo, 2016; Porto & Silva, 2014). Espera-se que essa tendência seja similar no contexto do mercado mobile app, em especial, no estágio de adoção (aquisição) que é mais equivalente ao contexto de compra da marca. Assim, propõe-se como hipóteses:

***H1: A força da marca está positivamente relacionada com o desempenho da marca de aplicativo no estágio de adoção.***

***H2: A força da marca está positivamente relacionada com o desempenho da marca de aplicativo no estágio de uso efetivo.***

Esses estudos em mercados de FMCG (Oliveira-Castro et al., 2008; Porto & Carvalho, 2015; Porto & Lima, 2015; Porto & Melo, 2016; Porto & Silva, 2014), evidenciaram, também, que o efeito da força da marca sobre indicadores de desempenho competitivo de marcas difere consideravelmente entre as categorias de bens. Espera-se que essa tendência se estenda ao mercado de apps, tanto para o estágio de adoção quanto para o estágio de uso efetivo, devido as

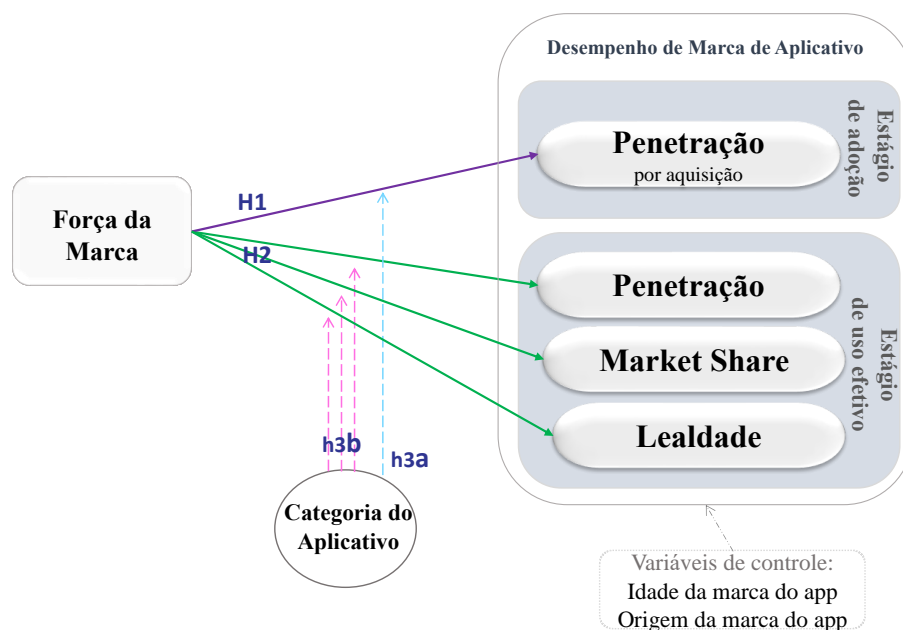
singularidades de interação dos consumidores com as categorias (Gera et al., 2020; Li et al., 2020b; Stocchi et al., 2021; Tang, 2019). Assim propõe-se:

**H3:** A categoria do aplicativo modera o efeito da força da marca sobre o desempenho da marca de aplicativo no estágio de adoção (H3a) e no estágio de uso efetivo (H3b).

Em vista disso, este estudo se propôs a testar as relações apresentadas no modelo de pesquisa (Figura 5). O modelo é formado por: uma variável independente – força da marca; quatro variáveis dependentes – sendo um indicador de desempenho de marcas de apps no estágio de adoção (penetração por aquisição) e três indicadores de desempenho de marcas de apps no estágio de uso efetivo (penetração, market share e lealdade); uma variável moderadora – categoria do app; e duas variáveis controles – idade da marca do app (Biviji et al., 2020) e origem da marca (Porto, 2019), que estudos anteriores apontam que elas podem interferir nas métricas de desempenho da marca.

**Figura 5**

*Modelo teórico*



### 3.2 Métodos

O presente estudo consiste em um quase-experimento em ambiente natural que visou analisar o efeito da força da marca no desempenho de marcas nos estágios de adoção e de uso efetivo. Esse tipo de abordagem experimental é similar ao experimento de campo natural, diferindo apenas no fato de que não há intervenção de um pesquisador. Isto é, os dados emergidos são totalmente orgânicos (Viglia et al., 2021). Para esse feito, em um primeiro momento, foi proposto e validado um modelo de medição de métrica de força da marca para marcas de bens digitais (apps).

A métrica aqui proposta é uma transposição da métrica de força da marca (construto MCQ – média da magnitude de familiaridade e qualidade percebida da marca), criada por Oliveira-Castro et al. (2008) com base em dados primários (perspectiva da demanda reivindicada via questionário), para uma métrica com base em dados secundários (perspectiva da demanda via metadados de loja de plataforma) (Foxall et al., 2021). Essa proposta foi motivada pela possibilidade de ampliar o escopo de consideração do contexto competitivo das marcas e inclusão de marcas menores (Porto, 2018, 2019).

As lojas de plataformas de aplicativos, como a Google Play Store, apresentam considerável potencial como fonte de dados para a medição e acompanhamento do desempenho das marcas de apps em relação aos aspectos de branding (Finkelstein et al., 2017; Gokgoz et al., 2021; Stocchi et al., 2021; Tavalaei & Cennamo, 2021), uma vez que as páginas dos apps na plataforma reúnem informações sobre as marcas, geradas pelos gestores da plataforma, da marca e consumidores. Essas informações estão disponíveis publicamente para análises e podem ser coletadas por meio de mecanismos de mineração de dados.

Com base em revisão de literatura e interpretação da abordagem analítico-comportamental, foi proposto que: o quantitativo de downloads e de avaliações, em conjunto, podem ser utilizados como uma métrica proximal mais robusta de conhecimento da marca de apps; e a classificação por estrelas é uma medida plausível para mensurar a qualidade percebida das marcas de aplicativos pelo consumidor, considerando o seu cenário competitivo. Como forma de ampliar o rigor e aplicabilidade de tal proposição, submeteu-se as medidas de mensuração proposta à validação por



especialistas de marketing e de tecnologia. Os detalhes do processo de validação, proposição do indicador de força da marca e estatísticas descritivas podem ser conferidos no Apêndice D.

### **3.2.1 Amostras**

Foram elaborados dois painéis de dados de consumidores do Centro-Oeste do Brasil, provenientes do banco de dados do projeto de pesquisa “M-Behavior” (ver Apêndice A), enriquecidos com metadados da loja de apps Google Play Store coletados por meio do processo de data scraping no Google Play Store, utilizando a RESTful API para a proposição do indicador de força da marca de marcas de bens digitais (apps) (consulte detalhes no Apêndice D).

#### **➤ Painel A**

O Painel A foi elaborado com o propósito de testar o efeito da força da marca no desempenho da marca no estágio de adoção (penetração por aquisição). O painel é composto por 773 marcas de aplicativos de quatro categorias (Comunicação, Educação, Saúde & Fitness e Social) que estavam instaladas nos dispositivos móveis com sistema operacional *Android* de 525 consumidores, entre os quais 55,05% eram voluntários do sexo feminino e idade média de 29,72 ( $dp=11,44$ ).

#### **➤ Painel B**

O Painel B foi elaborado com o intuito de testar o efeito da força da marca sobre o desempenho da marca (penetração, market share e lealdade) no estágio de uso efetivo. Para isso considerou-se as medições de 126 dispositivos com sistema operacional *Android* de consumidores com 28 dias ou mais de registro de atividades de uso de aplicativos, coletados no período de 23 de julho a 14 de novembro de 2020. Dos consumidores, 54,33% eram do sexo feminino, com idade média de 28,42 ( $dp=10,25$ ). O conjunto de dados resultante inclui um total de 348.362 registros de acessos padronizados a 237 marcas de apps das quatro categorias mencionadas anteriormente.

### 3.2.2 Tratamento e análise dos dados

Os dados referentes às marcas de ambos os painéis estão no nível agregado da marca. Na Figura 6 é apresentada a descrição operacional das variáveis dependentes ( $PA_j$  – penetração por aquisição;  $PU_j$  – penetração de uso;  $MU_j$  – market share de uso; e  $LC_j$  – lealdade comportamental), da variável independente ( $FM_j$  – força da marca) e das variáveis controle ( $IM_j$  – idade da marca e  $OM_j$  – origem da marca).

**Figura 6**

*Descrição das variáveis*

Grupo	Variável	Código	Descrição
Estágio de adoção	Penetração por aquisição da marca $j$	$PA_j$	A proporção de consumidores disponíveis que tinham a marca instalada a pelo menos um dia.
Estágio de uso efetivo	Penetração de uso da marca $j$	$PU_j$	A proporção de consumidores disponíveis que acessaram a marca pelo menos uma vez no período especificado.
	Market share de uso da marca $j$	$MU_j$	Total de acessos à marca como proporção do total de acessos à categoria no período especificado.
	Lealdade comportamental à marca $j$	$LC_j$	A taxa média de acessos à marca entre os seus consumidores no período especificado.
	Força da marca	$FM_j$	Média da magnitude de familiaridade e qualidade percebida da marca (consulte o Apêndice D)
	Idade da marca $j$	$IM_j$	A idade da marca em dias da sua disponibilização na loja de apps até o dia da coleta dos dados.
	Origem da marca $j$	$OM_j$	A origem da marca foi identificada considerando duas informações – endereço postal e site –, que constavam na página do app. Para os apps que apresentavam o endereço postal foi realizada a consulta do país de origem usando a API do Google Maps e os não possuíam endereço e/ou o endereço era nulo, foram consultados por meio do WHOIS ( <i>python-whois</i> versão 0.7.3) que retorna o endereço postal de cadastro do site. Após essa identificação, as marcas foram classificadas em: (0) Outros países e (1) Brasil

Todas as medidas contínuas calculadas foram relativizadas (divididas pelo valor médio da medida intra-categoria) para que houvesse comparações padronizadas de todas as marcas de apps, uniformemente. Em seguida, cada uma foi transformada em  $\log+1$ , com a finalidade de colocá-las na mesma ordem de grandeza.

Em um primeiro momento foram realizados testes para verificar se os dados atendiam aos pressupostos estatísticos para modelos de regressões clássicos. Uma vez constatado que os dados não atendiam plenamente aos pressupostos (normalidade, multicolinearidade e heterocedasticidade), optou-se pela utilização da Regressão Quantílica (RQ) – um modelo semi-paramétrico que fornece mais flexibilidade e robustez do que a regressão de mínimos quadrados ordinários (MQO) na modelagem de dados com heterogeneidade em sua distribuição condicional (Koenker, 2017; Koenker & Hallock, 2001).

Foram testados quatro modelos de RQ aplicados em cinco quantis das variáveis dependentes ( $\tau = \{0,05, 0,25, 0,50, 0,75 \text{ e } 0,95\}$ ) devido à característica dos dados em cauda longa, de modo que os modelos nos forneceram informações mais detalhadas ao longo da curva de distribuição (Equações 3.1 e 3.2).

$$(\tau)Y = \beta_0(\tau) + \beta_1(\tau)FM_j + \varepsilon \quad (\text{Eq. 3.1})$$

$$(\tau)Y = \beta_0(\tau) + \beta_1(\tau)FM_j + \beta_2(\tau)IM_j + \beta_3(\tau)OM_j + \varepsilon \quad (\text{Eq. 3.2})$$

Onde,

$\tau$  = parâmetro de estimação (Quantil)

$Y$  = variável dependente ( $PA_j$ ;  $PU_j$ ;  $MU_j$ ;  $LC_j$ )

$\beta_0$  = intercepto

$(\beta_1|\beta_2|\beta_3)$  = coeficientes angular

$FM_j$  = variável independente

$(IM_j|OM_j)$  = variáveis de controle

$\varepsilon$  = termo de erro

Após a estimação dos parâmetros dos modelos, foi realizado o teste de *Wald* para verificar se as diferenças observadas nos diferentes quantis ( $\tau$ ) eram realmente significativas, seguido da verificação de qualidade de ajuste do modelo por meio do *pseudo-R<sup>2</sup>* (Koenker, 2017; Koenker & Hallock, 2001).

### 3.3 Resultados

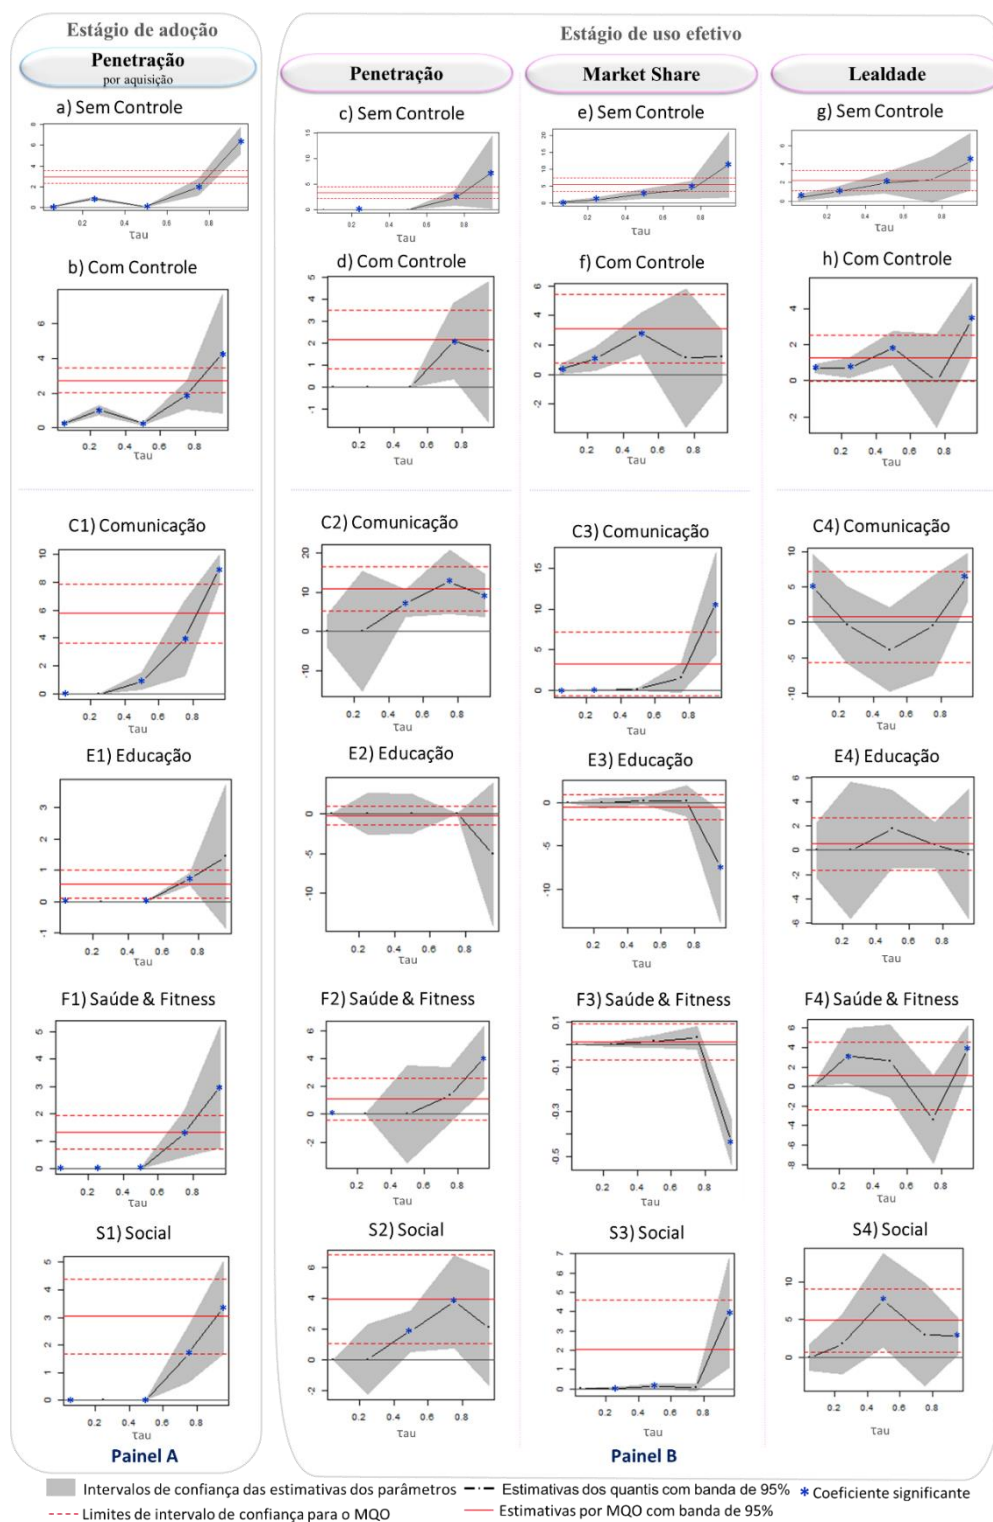
Antecipando a presença de não linearidade na relação da força da marca ( $FM_j$ ) nas métricas de desempenho das marcas de apps em ambos os estágios de interação ( $PA_j$ ;  $PU_j$ ;  $MU_j$ ;  $LC_j$ ), uma abordagem de regressão quantílica (RQ) foi usada para encontrar a natureza da variável de entrada em vários quantis das variáveis respostas. Os modelos de RQ em cinco quantis diferentes, ( $\tau = \{0,05, 0,25, 0,50, 0,75 \text{ e } 0,95\}$ ), foram avaliados e os resultados relacionados às estimativas de parâmetros e seu intervalo de confiança de 95% são dados nas Tabelas 11 a 14 (no Apêndice E) para os Modelos 1 e 2 (sem e com controle, respectivamente). Também foram testados modelos com moderação da categoria de app (Modelo 3 – sem controle; Modelo 4 – com controle): identificou-se que a categoria do app afeta a valência da relação da força da marca sobre as métricas de desempenho, conforme pode ser verificado nas Tabelas 15 a 18 (no Apêndice E).

Considerando os parâmetros de ajuste dos modelos (*Wald e pseudo-R<sup>2</sup>*), constatou-se que os modelos com variáveis controles ( $IM_j$  e  $OM_j$ ) obtiveram uma performance melhor. Desse modo, serão relatados os resultados dos Modelos 2 e 4 para cada métrica de desempenho da marca.

Uma representação visual dos coeficientes de mudança da força da marca e sua banda de confiança para os diferentes quantis são apresentados na Figura 7. Os gráficos mostram como o valor beta dos coeficientes (no eixo y) está mudando em diferentes quantis (eixo x). Se os coeficientes da RQ estiverem fora do intervalo de confiança do MQO (linhas vermelhas tracejadas) sinaliza que há uma diferença significativa (ao nível de 5%) entre o coeficiente de regressão MQO e os coeficientes de regressão RQ.

Figura 7

Modelos 1, 2 e 4 - Variação das estimativas dos coeficientes da RQ



### 3.3.1 Estágio de adoção

No estágio de adoção da marca, identificou-se que em todos os *quantis* o impacto direto da força da marca na penetração por aquisição de marcas de apps foi significativo e positivo, chegando a 4,27% de variação na penetração a cada 1% de aumento do *score* da força da marca, quando a penetração é alta ( $\tau=95$ ) (Gráfico b, Figura 7).

Ao considerar o impacto da força da marca na penetração, levando em conta as categorias dos apps, constatou-se que, apesar de a valência diferir, a relação é positiva para todas as categorias. Marcas com maiores penetração obtiveram um impacto mais forte, por exemplo, chegando a uma variação esperada de 8,90% na categoria de Comunicação e 2,99% na categoria de Saúde & Fitness a cada aumento de 1% no *score* da força da marca ( $\tau=95$ ).

### 3.3.2 Estágio de uso efetivo

No estágio de uso efetivo das marcas de apps constatou-se que o efeito principal da força da marca é positivo, mas varia consideravelmente para cada métrica de desempenho (Modelo 1).

Para a penetração de uso das marcas de apps, a força da marca apresentou variação positiva direta, mas significativa somente para marcas com penetração relativamente alta ( $\tau=75$ ,  $\beta=2,09$ ,  $p\leq 0,05$ ) (Gráfico d, Figura 7). Essa tendência de variação positiva persistiu no nível da categoria, exceto para categoria de Educação, sendo que a cada aumento de 1% na força da marca espera-se uma variação de 12,65% para categoria de Comunicação ( $\tau=95$ ), 4,04% para Saúde & Fitness ( $\tau=95$ ) e 3,77% para Social ( $\tau=75$ ) (Gráfico C2 a S2, Figura 7).

O impacto da força da marca no market share de uso é positivo e significativo para marcas de apps nos quantis de ( $\tau=5$ ) a ( $\tau=50$ ) (Gráfico f, Figura 7). Ao levar a análise para o nível da categoria, a tendência de influência mudou - verificou-se que para todas as categorias a força da marca apresenta um impacto significativo para marcas com alto *market share* ( $\tau=95$ ). Contudo, para marcas das categorias de Educação e Saúde & Fitness o efeito de uma pontuação mais alta no *score* da força da marca influenciou a participação de uso da marca de forma negativa (-7,43% e -0,44%, respectivamente), enquanto para as categorias de Comunicação e Social o efeito de uma pontuação mais alta no *score* da força da marca influenciou a participação de uso da marca de forma positiva (10,67% e 3,94%, respectivamente) (Gráfico C3 a S3, Figura 7).

Em relação ao efeito da força da marca na métrica de lealdade comportamental, constatou-se uma relação positiva e significativa com tendência crescente em todos os quantis, exceto ( $\tau = 0,75$ ) (Gráfico h, Figura 7). No nível da categoria, com exceção da categoria de Educação, pôde-se observar um impacto positivo e significativo da força da marca sobre marcas com maiores pontuações de lealdade comportamental ( $\tau = 95$ ). Contudo, o impacto varia consideravelmente entre categoria, sendo maior para marcas da categoria de Comunicação (7,74%). Para marcas com menores pontuações de lealdade das categorias de Comunicação ( $\tau = 0,05$ ) e Saúde & Fitness ( $\tau = 0,25$ ), a cada aumento de 1% na força da marca espera-se uma variação positiva na pontuação de lealdade (4,92% e 3,19%, respectivamente) (Gráfico C4 a S4, Figura 7).

### **3.4 Discussão dos resultados**

Este estudo analisou o impacto da força da marca no desempenho de marcas de apps em diferentes estágios de interação com o consumidor. Foram considerados dois painéis distintos para o teste do impacto da força da marca no desempenho da marca no estágio de adoção ( $n = 773$ ) e no estágio de uso efetivo ( $n = 237$ ). Para tanto, foi proposta e validada uma métrica de força da marca com base em metadados provenientes do ponto de distribuição (loja de apps) com base na proposta de Oliveira-Castro et al. (2008), viabilizando, assim, a inclusão de marcas menores que geralmente são negligenciadas em estudos que abordam métricas de desempenho composta por medidas perceptivas da demanda (familiaridade e qualidade percebida da marca) (Porto, 2018, 2019), e, por conseguinte, possibilitando uma maior abrangência do contexto competitivo real das marcas.

No estágio de adoção da marca de apps, mais equivalente ao contexto de compra da marca, o impacto direto da força da marca na penetração por aquisição foi significativo e positivo em todos os quantis (corroborando H1). Isto é, neste estágio o efeito é prevalente independentemente do tamanho da marca. Ao considerar a categoria, o formato de influência foi similar, mas o seu peso variou expressivamente (corroborando H3a) (Oliveira-Castro et al., 2008; Porto & Lima, 2015), revelando, ainda, que intra-categoria marcas com maiores penetração obtiveram um impacto mais forte.

Já ao considerar o estágio de uso efetivo, de modo geral, evidenciou-se que para os indicadores de desempenho de uso da marca o efeito da força da marca é positivo (corroborando

H2), mas esse efeito variou consideravelmente de acordo com a categoria do app (corroborando H3b). Contudo, identificou-se que o impacto da força da marca é mais prevalente sobre o indicador de lealdade comportamental, corroborando com os achados de Porto e Lima (2015) que evidenciaram que o impacto da força da marca pode variar consideravelmente para um mesmo conjunto de marcas, a depender do indicador de desempenho competitivo considerado.

No estágio de uso efetivo, cabe destacar que a categoria de educação diferiu consideravelmente da tendência das demais, revelando que a força da marca não possui efeito significativo sobre os indicadores de desempenho competitivo de marcas de apps, apresentando efeito significativo apenas para marcas com indicadores de market share mais elevados ( $\tau = 95$ ), porém negativo. Isso pode ser explicado com base na abordagem comportamental que revela que, a depender do contexto, outras estratégias mercadológicas são mais relevantes do que as de branding (Oliveira-Castro et al., 2008; Porto & Melo, 2016). Assim, poderia supor-se que estratégias de diferenciação da marca (benefícios utilitários programados) seja um antecedente mais pertinente para explicar os resultados de desempenho de marcas dessa categoria (cf. Foxall & Sigurdsson, 2013; Oliveira-Castro et al., 2008).

Assim, os resultados empíricos, em conjunto, revelaram que a força da marca prevê o desempenho competitivo de marcas, apresentando efeito direto significativo e positivo, mas a valência de seu efeito variou consideravelmente para cada indicador de desempenho, corroborando achados de estudos anteriores (Porto & Lima, 2015; Porto & Silva, 2014), bem como a relação entre a força da marca e o desempenho da marca variou de acordo com as categorias de apps (evidência de moderação) (Oliveira-Castro et al., 2008; Porto & Carvalho, 2015; Porto & Lima, 2015; Porto & Melo, 2016; Porto & Silva, 2014).

### **3.5 Considerações Finais**

O presente estudo apresentou contribuições teóricas e metodológicas para a literatura de gestão de marcas, marketing para aplicativos e perspectiva comportamental. Primeiramente, este estudo ampliou o escopo da pesquisa de perspectiva comportamental ao contexto do mercado mobile app, ao realizar a transposição da métrica de força da marca com base em dados primários (Oliveira-Castro et al., 2008) para uma métrica com base em dados secundários aplicada para aplicativos. A métrica proposta se revelou capaz de ampliar o escopo de consideração do contexto



competitivo das marcas e possibilitou a construção de um ranking de marcas intra-categoria com base no score de força da marca. Este estudo fornece, assim, um modelo de medição que permite avaliar não somente a força de uma marca ao longo do tempo, mas, também, o quanto uma marca é mais forte em relação às concorrentes intra-categoria.

Em segundo lugar, contribuiu-se para a literatura de gestão de marcas e marketing para aplicativos ao oferecer as primeiras evidências referentes ao impacto da força da marca sobre indicadores competitivos de marcas de apps nos diferentes estágios de interação consumidor-marca, respondendo, também, a estudos anteriores que apontaram a necessidade da proposição e direcionamentos de formas de monitorar as atividades de branding de apps, bem como que evidenciasse o potencial de dados dos diferentes atores contidos na loja de apps.

Em geral, os resultados apontam que quanto mais forte a marca for, melhor será o seu desempenho nos estágios de adoção e uso efetivo pelo consumidor. Contudo, esse efeito variou consideravelmente de acordo com a categoria do app (evidência de moderação). O estudo detectou padrões de resultados de efeito da força da marca sobre indicadores de desempenho competitivo entre categorias em diferentes estágios de interação consumidor-marca. Gestores e cientistas de marketing poderiam considerar os parâmetros de métrica aqui propostos para monitorar os resultados dos desempenhos das marcas.

Neste direcionamento, o estudo também fornece implicações práticas, complementando as soluções existentes ao fornecer mecanismos para medir e analisar a força da marca de apps em relação à dinâmica do mercado, bem como em diferentes estágios de interação com o consumidor, contribuindo, assim, para a aproximação da academia e o mercado, uma vez que a métrica aqui desenvolvida pode facilmente ser implementada em painéis de monitoramento de marcas de apps por gestores e/ou desenvolvedores, podendo, até mesmo, ser atualizada em tempo real, o que poderia contribuir para a formulação de estratégias de marketing mais adequadas e realistas com o contexto competitivo da marca.

Apesar das contribuições que este estudo oferece, ele não está isento de limitações, como: i) foram consideradas apenas quatro categorias de apps; e ii) foram considerados apenas dois painéis com dados comportamentais do mercado brasileiro de apps para testar o impacto da força da marca sobre desempenho de marcas de apps. Assim, estudos futuros poderiam considerar outras categorias de apps e painéis de outros mercados de apps para verificar a generalidade e condições

em que os resultados se mantêm, bem como considerando marcas de bens digitais de outros segmentos para validar a robustez e replicabilidade da métrica de força da marca aqui proposta.

Os resultados deste estudo lançam luz de que outras variáveis situacionais sob o controle de gestores de marcas e da loja de apps poderiam explicar o desempenho da marca de apps como, por exemplo, estratégias de diferenciação (benefícios utilitários programados) das marcas que está sob o controle relativo de gestores. Estudos futuros poderiam considerar análise do impacto dessa variável sobre o desempenho, bem como propor e validar uma métrica mensurada de forma mais automatizada e menos arbitrária (i.e., estratégia de sistema forçado) (Foxall et al., 2021).

Com base na métrica de força da marca aqui proposta, estudiosos também poderiam avançar o conhecimento sobre quais diferenciais de branding e atributos do bem contribuíram para a construção de marcas de apps mais fortes, em especial explorando o potencial de dados reais integrados/contidos no ponto de distribuição da marca (loja de apps).

Por fim, mas não menos importante, considerando que estudiosos têm elucidado a pertinência de ampliar o escopo de estudos sob a perspectiva comportamental que relacionem antecedentes do nível individual do comportamento de compra do consumidor ao nível agregado de análise da marca (Oliveira-Castro et al., 2008; Porto & Oliveira-Castro, 2015), estudos futuros poderiam testar o caminho inverso com a medida proposta neste estudo – desagregando a métrica de força da marca para o nível do consumidor como uma medida proximal de benefício informativo programado pela marca.

#### **4 Comportamento de uso de marcas de aplicativos: influência de variáveis situacionais - Estudo 3**

Nos Estudos 1 e 2 foram realizadas análises no nível agregado da marca de aplicativos. Embora a consideração desse nível de análise seja usual para avançar o entendimento acerca do desempenho da marca, as perspectivas do consumidor gerariam insights adicionais sobre a interação consumidor-marca no contexto de uso efetivo. Segundo Keller (2021, 2022), em um mundo cada vez mais virtual, tendência amplificada por uma pandemia desafiadora, exigirão insights ainda mais aprofundados no nível individual do consumidor para um entendimento mais completo das marcas e branding neste contexto.

Em uma visão macro, Hair e Sarstedt (2021) complementam alertando que o grande quantitativo de dados no âmbito digital tentará analistas e cientistas de marketing a defender uma abordagem puramente baseada em dados em níveis agregados para a ciência e a tomada de decisões de negócios, podendo levar a noções equivocadas de que, com dados suficientes, os números falam por si só, logo dando ênfase no *como* e obscurecendo o *porquê*. Em mutualidade pelo prisma da perspectiva comportamental, estudiosos há tempos têm elucidado a pertinência de ampliar o escopo de estudos de marketing que relacionem antecedentes do nível individual do comportamento de compra do consumidor ao nível agregado de análise da marca para esse fim (Foxall et al., 2021; Oliveira-Castro et al., 2008; Porto & Oliveira-Castro, 2015). Assim, neste estudo, propõe-se contribuir para o avanço do conhecimento ao testar o caminho inverso, trazendo dados de ambos os estudos anteriores no nível agregado da marca para o nível de análise do consumidor.

Pela óptica da abordagem do marketing baseado em evidências, cientistas de marketing, usando dados agregados de compra, têm demonstrado que consumidores integralmente leais a uma única marca são a exceção à regra, postulando, assim, que os consumidores normalmente não consomem uma única marca favorita, nem todas as marcas de uma categoria, mas uma pequena variedade de marcas que podem ser adquiridas em proporções dessemelhantes por cada um. Ou seja, o padrão é a compra de repertório de marcas pelos consumidores (Driesener & Rungie, 2022; Ehrenberg et al., 2004; Sharp et al., 2012). No Estudo 1, avançou-se e estendeu-se esse conhecimento para o contexto de uso efetivo de marcas, ao demonstrar que o padrão persiste.

No Estudo 2, com aporte na abordagem comportamental, complementou-se as descobertas do Estudo 1 ao evidenciar que o antecedente força da marca (programado e controlado por gestores)

é um preditor importante do desempenho de marcas de apps nos estágios de adoção e uso efetivo pelo consumidor. Essa variável poderia ser trazida para o nível do consumidor como uma medida proximal de reforço (benefício) informativo programado da marca (Oliveira-Castro et al., 2008). Porém, quando se pretende investigar os preditores do comportamento de uso de marcas no nível individual do consumidor, existem muitos outros fatores que podem ser considerados, tanto sob o controle relativo de gestores quanto do consumidor.

O Modelo de Perspectiva Comportamental (BPM) – dispositivo integrador dominante na análise do comportamento do consumidor – considera que o comportamento do consumidor é precedido por fatores do cenário de consumo (estímulos físicos, sociais, temporal, regulatório) e história de aprendizagem do consumidor (cumulativo de experiências passadas), e resultam em consequências comportamentais que, por sua vez, moldará novos estímulos para comportamentos semelhantes no futuro (Foxall, 1990, 2015; Foxall et al., 2021). Vale ressaltar que, segundo Foxall (1998), o conceito de cenário de consumo não abarca apenas o ambiente imediato do consumo, mas, também, o tipo de controle (i.e., fonte e natureza) que esse ambiente exerce sobre o comportamento. Esse controle inclui a capacidade de autocontrole em que os consumidores podem organizar as contingências a que estão sujeitos.

Estudiosos sob a perspectiva comportamental (cf. Cavalcanti et al., 2013; Foxall, 2015; Foxall et al., 2021) têm sugerido que fatores relacionados a aspectos da vida dos consumidores (fatores não gerenciáveis), que configuram o cenário de consumo e estão sob o controle relativo do consumidor (e.g., levar acompanhante ao fazer compras – estímulo social), são preditores mais fortes no contexto de compra da marca, bem como fatores relacionados à história de aprendizado do consumidor (e.g., experiência passada com a marca e categoria do bem).

Todavia, em determinadas circunstâncias, os estímulos programados e sob controle relativo de gestores de diferentes instâncias (fatores gerenciáveis) prevalecem e predizem melhor as escolhas de marcas pelo consumidor (Foxall et al., 2004, 2021). Esses autores, sob a perspectiva comportamental, têm demonstrado, por exemplo, que a configuração do ambiente físico (ponto de venda), promoções e benefícios (reforços) programados pelas marcas podem influenciar no volume e recorrência de compra da marca (Foxall et al., 2004; Oliveira-Castro & Marques, 2017; Porto & Oliveira-Castro, 2015), assim como evidenciam que a magnitude do reforço programado das marcas contribui para explicar como os consumidores formam os seus repertórios de preferências de marcas em diferentes mercados de compra repetida (Foxall et al., 2004, 2021).

Nessa perspectiva, cientistas comportamentais (Foxall et al., 2021; Porto & Oliveira-Castro, 2013b) ressaltam a importância/pertinência de considerar a experiência passada do consumidor em projetos de pesquisa comportamental como fator potencial de interação com as variáveis da configuração do cenário de consumo na predição das respostas comportamentais do consumidor, uma vez que o modelo da perspectiva comportamental (BPM) enfatiza que o comportamento do consumidor somente ocorre com interação constante de fatores da história de aprendizagem e fatores do cenário de consumo – denominado de situação do consumidor (cf. Foxall, 1990, 2015). Porto e Oliveira-Castro (2013b) argumentam que, em geral, embora as previsões não interativas apontem para a direção correta, prevendo correlações entre variáveis do cenário de consumo e o comportamento de escolha da marca, elas podem subestimar seu verdadeiro efeito sobre comportamentos subsequentes.

Apesar da grande contribuição da abordagem de perspectiva comportamental para o avanço na compreensão de padrões de preferências de marcas pelo consumidor e seus antecedentes no contexto de compra, há espaço para novas pesquisas de campo que avancem esse entendimento para o contexto de uso efetivo de marcas, mais especificamente, considerando marcas de bens digitais (apps) e os comportamentos de uso da marca – frequência (incidência) de uso e alteração do repertório.

O aporte no arcabouço teórico-metodológico do BPM contribuiria para a chamada emergente de estudiosos mercadológicos, baseados em revisões da literatura que abrangem o mobile marketing, por mais pesquisas com respaldo em teorias e metodologias comportamentais para avançar o conhecimento sobre fatores situacionais que impulsionem a adoção e o consumo de bens (marcas) digitais (Hair & Sarstedt, 2021; Stocchi et al., 2021; Tong et al., 2020).

Neste contexto, a revisão integrativa da literatura de Stocchi et al. (2021), sobre o papel principal dos aplicativos no marketing e nas experiências do cliente, também revelou a necessidade de estudos sobre o repertório de marcas de apps, bem como sobre o que sustenta, com o tempo, as alterações de repertório de marcas de apps que os consumidores consomem. A pesquisa ainda evidencia que é incipiente investigações sob o prisma do marketing com dados reais de uso no nível do consumidor ao que tange a marca do app, reforçando, assim, a pertinência da realização deste estudo.

Estudos anteriores também têm apontado que a experiência mobile do consumidor – aprendizagem acumulada pela interação e vivências com a tecnologia mobile – pode afetar a força

da relação entre antecedentes e intenção de uso de apps (Japutra et al., 2021; Tam et al., 2020). Porém, até onde as pesquisas consultadas têm demonstrado, não há constatações em relação ao uso efetivo de marcas de aplicativos (Gera et al., 2020; Stocchi et al., 2021). Nesta conjuntura, visando contribuir para as lacunas apresentadas, o presente estudo pretende responder as seguintes questões de pesquisa: Quais fatores situacionais influenciam o comportamento de uso efetivo de marcas de apps? E esse comportamento de uso efetivo de marcas de apps difere conforme a experiência mobile do consumidor?

Assim, diante do exposto, têm-se como objetivo: **analisar a influência de variáveis situacionais sob o controle relativo do consumidor (estímulo temporal e social) e de gestores (estímulos do ambiente virtual) sobre o comportamento efetivo de uso de marcas de aplicativos (frequência de uso e alteração do repertório) pelo consumidor, testando moderação da experiência mobile do consumidor.**

A estrutura do presente estudo está organizada da seguinte forma: primeiramente, são apresentados o referencial teórico e o desenvolvimento das hipóteses, com suporte no modelo de perspectiva comportamental (BPM) (cf. Foxall, 1990, 2010, 2016) que sugere que o comportamento de uso efetivo de marcas de aplicativos pode ser explicado por variáveis situacionais – cenário de consumo e história de aprendizagem do consumidor. Deste modo, nas seções 4.1 e 4.2 discute-se acerca dessas variáveis sob a óptica do arcabouço teórico-metodológico do BPM, tangenciando com evidências de estudos referentes ao contexto de uso de marcas de apps. Em seguida, apresenta-se os métodos implementados; posteriormente, são apresentados os resultados seguidos da discussão, contribuições e implicações dos achados; finalmente, as limitações e sugestões de pesquisas futuras são delineadas.

#### **4.1 Cenário de consumo de marcas de aplicativos**

Pelo modelo de perspectiva comportamental, a configuração do comportamento do consumidor compreende o cenário de consumo atual, constituído por um conjunto de variáveis ambientais (físico, temporal, social e/ou verbal) moduladoras da função dos estímulos discriminativos e operações motivadoras que estimulam ou inibem a emissão de respostas do consumidor (Foxall, 2010, 2016; Foxall & Sigurdsson, 2013; Foxall & Yani-de-Soriano, 2005). Em síntese, são os estímulos discriminativos que proporcionam oportunidades de reforço

contingente à ocorrência de comportamentos específicos de consumo e às operações motivadoras que aumentam as qualidades de reforço dos bens (marcas) adquiridos e consumidos (Foxall, 2016; Foxall & Sigurdsson, 2013).

A configuração do cenário abrange a fonte e natureza de controle que os estímulos exercem sobre o comportamento. O grau desse controle depende do nível de abertura do cenário, de modo que a configuração varia em seu escopo e capacidade de evocar respostas, formando um *continuum* relativamente aberto-fechado. Em cenários relativamente mais abertos tende a ocorrer menos restrições e/ou pressão por determinados padrões comportamentais, resultando, assim, em maior diversidade de escolha e possibilidades de comportamentos (o reforço positivo predomina), enquanto em cenários relativamente mais fechados as escolhas são mais restritas, podendo ocorrer maior pressão por determinados padrões de comportamentos definidos, em grande parte, ou inteiramente, por outrem (o reforço negativo é prevalente) (Foxall, 1998b; Foxall & Yani-de-Soriano, 2005).

De acordo com o BPM, esse grau de abertura ou fechamento deve ser considerado para um melhor entendimento de variáveis preditoras do comportamento (cf. Foxall, 2009, 2010, 2016; Foxall et al., 2004), pois a amplitude de opções comportamentais disponíveis (no sentido de grau de liberdade que o consumidor desfruta) varia ao longo desse *continuum* aberto-fechado (Foxall et al., 2013). Sob essa perspectiva, nos próximos subtópicos serão abordadas algumas possíveis variáveis situacionais que compõem a configuração do comportamento de uso efetivo de marcas de apps.

#### ***4.1.1 Estímulos da dimensão espacial***

A configuração física do comportamento, de acordo com o BPM, inclui uma ampla gama de fatores ambientais como tamanho da loja, aroma ambiente, posicionamento dos bens na prateleira e embalagem do produto (Foxall, 1990, 2015). É amplamente reconhecida a capacidade desses estímulos físicos de influenciarem o comportamento do consumidor (e.g., Bosmans, 2006; Davies et al., 2003; Knoferle et al., 2012; Michon et al., 2005; Porto & Oliveira-Castro, 2013a, 2013b, 2015; Turley & Milliman, 2000).

Contudo, ao pensar em configurações do âmbito virtual, pode não parecer mais adequado nomear como *ambiente físico* dado que é uma realidade com aspectos diferentes. Nesta conjuntura,

propõe-se no presente estudo denominar essa dimensão de forma mais ampla, com base no behaviorismo radical (Skinner, 2003), de *Dimensão Espacial*, abarcando, assim, tanto o ambiente físico quanto o ambiente virtual, doravante no presente estudo mencionado como estímulos do ambiente virtual.

No caso do consumo de marcas, em uma perspectiva mais ampla, pode-se considerar que uma parcela dos estímulos discriminativos que compõem a configuração do cenário de uso efetivo de marcas de apps são programados e controlados (até certo ponto) por gestores de diferentes instâncias do ecossistema mobile. Alguns desses possíveis estímulos do ambiente virtual, sob o controle dos gestores, são: fator tecnológico (e.g., atributos do dispositivo móvel e conectividade), categoria do app e reforço programado da marca.

#### *4.1.1.1 Fator Tecnológico: atributos do dispositivo móvel e conectividade*

O contexto tecnológico das marcas de aplicativos depende, substancialmente, de variáveis tecnológicas dos dispositivos móveis e da conectividade que estão sob o controle de gestores de outras instâncias do ecossistema mobile. Esses dois fatores podem influenciar direta e indiretamente na experiência do consumidor com a marca (Stocchi et al., 2021). Os recursos tecnológicos dos dispositivos móveis, na perspectiva do BPM, podem funcionar como fatores virtuais restritivos ou facilitadores (Foxall, 2016; Foxall & Sigurdsson, 2013).

Estudos que investigaram a intenção de uso de apps de distintas categorias evidenciaram que a dimensão da tela do dispositivo móvel influencia na intenção de uso de apps (Al Ghamdi et al., 2015; McLean et al., 2018; Natarajan et al., 2018) à medida que os usuários executam, cada vez mais, multitarefas usando o smartphone. Outras características dos dispositivos móveis que podem apresentar influência no comportamento de uso de aplicativos são a capacidade de processamento (RAM – *Random Access Memory*) e armazenamento interno (CPU – *Central Processing Unit*) (Bijlani et al., 2021; Fogg, 2019; Hill, 2021; Sims, 2017), uma vez que o seu tamanho pode limitar/ampliar a capacidade de uso e tamanho do repertório de apps do usuário. Sendo assim, pode-se supor que quanto mais elevado os atributos do dispositivo móvel (maior tela, RAM e CPU) uma maior amplitude de opções comportamentais estariam disponíveis aos consumidores.

No que tange a conectividade, em geral, os mobile app dependem de uma conexão com a internet para funcionarem, mesmo os apps que funcionam *offline* em algum momento precisarão



da conexão para sincronizar as atividades realizadas e atualizarem para uma possível nova versão. Estudos que investigaram a *Quality of Experience (QoE)* de aplicativos mobile usados em Wifi ou rede móvel constataram que: mesmo interrupções de conexões de curta duração (*i.e.*, cair para 0 Mbps por alguns milissegundos) possuem um grande impacto negativo na experiência do usuário final (Casas et al., 2016), da mesma forma como sessões longas de uso de app usados em rede móvel frequentemente têm pior *QoE* do que sessões mais curtas (Masi & Wac, 2019). Com base no elucidado, e considerando que diversos aplicativos demandam uma grande quantidade de transmissão de dados e que o custo de pacotes de dados móveis varia consideravelmente em diferentes lugares e por operadoras (Cable, 2019), pode-se esperar que a conectividade Wifi caracteriza-se como um cenário relativamente mais aberto e estaria relacionado a uma maior ocorrência de comportamento de uso de apps.

#### 4.1.1.2 Categoria do aplicativo

Sob o prisma do BPM (Foxall, 2016; Foxall & Sigurdsson, 2013), a categoria do app pode atuar como um estímulo discriminativo programado e controlado pelos gestores das plataformas de lojas de app (ao que tange o nível de especificação e estratégia de promoção) e, até certo ponto, pelos gestores das marcas de apps.

Estudo recente (Li et al., 2020b) sobre a estrutura evolutiva dos ecossistemas de aplicativos mobile indicou que várias categorias de apps estão conectadas e que as diferenças entre-categorias motivam os consumidores a usarem várias categorias. E apresenta indícios de que as categorias de Comunicação e Social funcionam como as bases do ecossistema e a ponte para conectar diferentes categorias, sendo as categorias mais populares. Em complementaridade, outros estudos – que investigaram a intenção de adoção e continuidade de uso de aplicativos – apontam que um dos fatores que influenciam a intenção de comportamento futuro é o uso de aplicativos da mesma categoria (Chiu et al., 2021; Huang et al., 2019; Kim et al., 2017; Zhao et al., 2016).

Com base no exposto, pode-se esperar que a categoria dos apps utilizados esteja relacionada positivamente com a frequência de uso e a ocorrência de alteração do repertório de marcas de aplicativos, bem como uma maior ocorrência de comportamento de uso de marcas de apps esteja relacionada a configurações com alta proporção de uso das categorias de Comunicação e Social.

#### *4.1.1.3 Reforço informativo programado pelas marcas de aplicativos*

Estudiosos têm corroborado a tese, conforme proposto pelo BPM, de que os reforços programados (utilitário/informativo) pelas marcas são centrais para a formação do repertório de compra de marcas do consumidor (Cavalcanti et al., 2013; Foxall, 2004; Kachuba & Oliveira-Castro, 2020; Oliveira-Castro & Foxall, 2017; Oliveira-Castro et al., 2008; Porto & Oliveira-Castro, 2015), de modo que, ao mensurar a magnitude do reforço programado da marca, considerando o seu contexto competitivo (categoria do bem), pode permitir a identificação de padrões de escolha do consumidor (Foxall et al., 2021).

No contexto de compra da marca, estudiosos têm evidenciado que o repertório de marcas dos consumidores é formado, predominantemente, com base no nível de reforço programado pelas marcas (utilitário/informativo). E que os consumidores tendem a maximizar a quantidade/qualidade de reforços que adquirem ao escolher entre as marcas, comprando aquelas com maior combinação de benefícios, considerando a amplitude de opções comportamentais disponíveis (Foxall, 2015; Foxall et al., 2021; Oliveira-Castro & Foxall, 2017). Isto é, os consumidores demonstram padrões comportamentais de preferências em prol de marcas com maiores magnitudes de reforços.

Nesse direcionamento, estudos têm enfatizado a valia de considerar o componente simbólico/social para explicar o comportamento de escolha e preferência de marcas pelo consumidor, seja ao que tange a magnitude do reforço informativo (geralmente, separados em três níveis – baixo, médio e alto) e/ou a variedade da qualidade do reforço considerado (Kachuba & Oliveira-Castro, 2020; Oliveira-Castro & Foxall, 2017; Oliveira-Castro et al., 2008; Porto & Oliveira-Castro, 2015).

Oliveira-Castro et al. (2005a) investigaram a dinâmica da compra repetida (ocasiões de compras) para grupos de marcas pertencentes a níveis semelhantes de reforço informativo. Os resultados apontaram que, enquanto a probabilidade de compra repetida sequencial diminui ao longo de um período, a probabilidade de compra não sequencial aumenta em proporção semelhante, constatando que o grau de penetração de um grupo de nível de reforço de marcas é composto por consumidores com compra repetida sequencial e consumidores com compras não sequenciais, revelando, assim, que em alguma dada ocasião os consumidores tendem a consumir marcas de diferentes níveis de reforço.

Contudo, estudiosos demonstraram que aumentos no reforço programado pelas marcas aumentam a quantidade que os consumidores adquirem. Cavalcanti et al. (2013) complementam que consumidores que consomem marcas com nível informativo superior possuem repertório de compra de marca mais restrito. Por outro lado, consumidores que consomem marcas com reforço informativo relativamente inferior apresentam repertório de marca maior.

Considerando os resultados de estudo de mercado, que apontam que os consumidores possuem uma baixa tolerância com apps que falham em atender às expectativas, que culminam em desinstalação, por exemplo, no primeiro trimestre de 2021, a taxa de retenção média de usuários por apps no mercado brasileiro foi de 23% no primeiro dia e apenas 5,8% no sétimo dia após a instalação (AppsFlyer & App Annie, 2021). Pode-se supor que apps com menores magnitudes de reforço informativos seriam apenas consumidos devido a possíveis operações motivadoras e/ou por fornecerem um nível alto de reforço utilitário.

Com base no exposto, parece razoável supor que o reforço informativo programado pelas marcas seria um dos preditores mais forte do uso efetivo de marcas de apps. A presente pesquisa postula que em ambiente virtual os consumidores que consomem mais marcas de aplicativos com alta magnitude de reforço informativo programado tenderão a usar as marcas com maior frequência e tenderão a alterar menos os seus repertórios de marcas de aplicativos. Por outro lado, consumidores que consomem marcas de aplicativos com uma maior variedade de qualidade de reforço informativo programado tenderão a alterar mais os seus repertórios e tenderão a apresentar uma frequência de uso relativamente maior.

#### ***4.1.2 Estímulos Temporais***

A configuração temporal refere-se a fatores relacionados ao tempo que afetam a escolha do consumidor (Foxall, 2009). No individual do consumidor, fatores temporais (*e.g.* os dias da semana e horários) regem a sua rotina e contribuem para a configuração de hábitos e padrões de comportamento.

No âmbito mobile, estudos anteriores apontam que a distribuição do tempo despendido por dia em dispositivo e apps tende a variar consideravelmente intra e entre sujeitos (Zhu et al., 2018), bem como nos períodos do dia e durante a semana versus final de semana (Deng et al., 2019; Zhu et al., 2018).

Mais especificamente, verificou-se que durante o dia o uso de dispositivos Android é moderadamente ativo, intensificado à noite e raríssimo de madrugada (Zhu et al., 2018); que à noite a ocorrência de download, atualização e desinstalação de apps tende a ser mais elevada (Li et al., 2015); o nível de interação com apps, dada às suas categorias, varia de acordo com o horário, por exemplo, Guan et al. (2019) identificaram que os *mHealth Apps* são usados mais entre 11h-13h e 18h-21h e a interação é maior durante o final de semana. De forma consistente, outros estudos encontraram que apps das categorias de Ferramentas e de Educação são mais usados durante a semana (Deng et al., 2019). Já apps da categoria de Social são usados frequentemente no decorrer de todo o dia, sendo a intensidade de uso mais elevada nos finais de semana (Deng et al., 2019; Li et al., 2020a; Wang, 2020).

Esses estudos apontam para a tendência de que os usuários preferem se envolver mais com *apps* diversos em horários não comerciais. Uma interpretação plausível na perspectiva comportamental consiste que nesse período o cenário de consumo seria relativamente mais aberto, o que possibilitaria uma maior gama de comportamento (Foxall, 1998b; Foxall et al., 2013; Foxall & Yani-de-Soriano, 2005). Nessa perspectiva, dada a onipresença das marcas na mão, pode-se considerar que estímulos temporais na configuração do comportamento de uso de marcas de apps estão consideravelmente sob o controle do consumidor.

#### **4.1.3 Estímulo Social**

O contexto social de consumo tem sido investigado em diferentes perspectivas e por diversas áreas do conhecimento. Estímulos do contexto social de consumo inclui os possíveis indivíduos que podem estar presentes no momento em que as escolhas são feitas (e.g., vendedores na loja e acompanhantes do consumidor), bem como a sua compreensão das preferências e escolhas dos demais socialmente interligados, normas sociais e os aspectos da situação que depreende tais normas (Foxall, 1999, 2009, 2015, 2016).

No âmbito *offline* de escolha da marca, estudos com embasamento analítico-comportamental têm constatado a influência desse tipo de estímulos na escolha do consumidor (e.g. Almeida et al., 2020; Kachuba & Oliveira-Castro, 2020; Oliveira-Castro et al., 2011). No âmbito virtual (mobile) de escolha da marca, com esse embasamento (até onde se sabe), ainda não há constatações.

Em uma perspectiva ampla, o consumidor mobile apps pode estar exposto aos efeitos de estímulos sociais que abarcam o contexto *online-offline* (Stocchi et al., 2021). Mesmo que os smartphones sejam de uso pessoal, por exemplo, o consumidor tem o controle de compartilhar o dispositivo com pessoas do seu convívio. Essas pessoas, por sua vez, podem estar consumindo apps diversos no dispositivo.

Pela perspectiva do BPM, o compartilhamento do dispositivo móvel sinaliza uma possível amplitude na evocação de respostas (Foxall et al., 2013). Em outras palavras, uma maior frequência de uso e ocorrência de alteração de repertório de marcas de apps tenderiam a estarem relacionadas a configurações de cenários que há compartilhamento do smartphone com outrem.

Com base no elucidado, sobre a configuração do comportamento de consumo efetivo de marcas de apps (frequência de uso e alteração do repertório), é passível supor que o efeito provável de estímulos do ambiente virtual sobre a probabilidade de uma resposta comportamental (uso e alteração do repertório) seja mais forte do que de estímulos temporal e social. Nesse direcionamento, observa-se que os estímulos que compõem o cenário podem ser discriminados pela perspectiva de controle relativo do consumidor (estímulo temporal e social) e de gestores de diferentes instâncias do ecossistema mobile (estímulos do ambiente virtual). Considerando essa perspectiva, propõe-se:

*H1a: Os estímulos do cenário de situação de consumo programados e controlados pelos gestores são preditores mais fortes do que os estímulos controlados pelo consumidor sobre a frequência de uso de marcas de aplicativos.*

*H1b: Os estímulos do cenário de situação de consumo programados e controlados pelos gestores são preditores mais fortes do que os estímulos controlados pelo consumidor sobre a alteração do repertório de marcas de aplicativos.*

## **4.2 Experiência Mobile do Consumidor**

Considerando a proeminência da multidisciplinaridade que o presente estudo está situado, salienta-se que a experiência do consumidor pode ser mensurada e interpretada de diferentes ópticas ao longo da jornada do consumidor que, por sua vez, é moldada por uma diversidade de fatores contextuais e individuais (cf. Lemon & Verhoef, 2016; Sellier et al., 2021; Stocchi et al., 2021). Este estudo concentrou-se na experiência do consumidor que particularmente foca mais nos

significados pessoais da experiência do consumo (*i.e.*, experiências anteriores {t-n}) (Foxall, 2016; Lemon & Verhoef, 2016).

Pela perspectiva do BPM, o efeito cumulativo de experiências já vivenciadas pelo consumidor em situações de escolha que produziram consequências reforçadoras/punitivas, que molda a individualidade do consumidor, reflete a história de aprendizagem do consumidor (Foxall & Sigurdsson, 2013) que, por sua vez, é responsável por atribuir significados a estímulos até então neutros em situações semelhantes subsequentes (Foxall, 2015, 2016). E, segundo Porto e Oliveira-Castro (2013b), essa influência pode variar conforme a experiência passada do consumidor com a marca.

A experiência mobile do consumidor – aprendizagem acumulada pela interação e vivências com a tecnologia mobile – pode ser considerada como uma variável de história de aprendizagem. Estudos anteriores apontam que a experiência passada do consumidor propende a aumentar a familiaridade com a tecnologia, podendo resultar na redução de barreiras de adoção e uso contínuo de aplicativos mobiles (Alam et al., 2020; Flaherty et al., 2021; Japutra et al., 2021; Kim et al., 2017; Natarajan et al., 2017; Son, 2017; Tam et al., 2020).

Considerando a recomendação de Lemon e Verhoef (2016), de que estudos futuros devem ir além dos caminhos comuns de investigação da experiência do consumidor (e.g., dados provenientes de *survey*) e considerar a crescente presença de *big data* (e.g., dados de transações, canais e operacionais), e com aporte no arcabouço teórico-metodológico do BPM, acredita-se que o nível de uso de dispositivo móvel (tempo de interação diário – Beaunoyer et al., 2020; Deng et al., 2019), o repertório inicial de marcas de aplicativos por nível de reforço informativo e a inovatividade do consumidor podem ser considerados como fatores da história de aprendizagem do consumidor mobile que tendem a influenciar no consumo de marcas de aplicativos.

Estudo (App Annie, 2017) realizado em 10 países constatou que os consumidores mobile possuem um repertório geral médio de uso efetivo de 30 aplicativos por mês. Os brasileiros usam cerca de 40 aplicativos por mês, além de possuírem um repertório geral em torno de 85 aplicativos instalados no dispositivo móvel. Aproximadamente 70% da amostra total investigada acrescenta, pelo menos, um novo aplicativo por mês ao seu dispositivo; enquanto 30% dos usuários brasileiros instalam 4 ou mais aplicativos durante o mesmo período. Considerando esse fato, pode-se esperar que o tamanho do repertório inicial de marcas de aplicativos por nível de reforço dos consumidores revele variedades e magnitudes de estímulos ao longo da vida com a experiência mobile.

Na literatura de psicologia e marketing a inovatividade do consumidor é geralmente aceita como um traço de personalidade. Segundo Goldsmith e Foxall (2003, p. 324) a “inovatividade refere-se a diferenças interindividuais que caracterizam as respostas das pessoas a coisas novas”. Os autores salientam que não há uma definição única referente a inovatividade, pois dependerá da abordagem e/ou o nível de investigação que o pesquisador pretende aderir ao mensurar a inovatividade do consumidor.

A inovatividade do consumidor em pesquisas no segmento mobile, geralmente, têm a relacionado à atitude e/ou intenção comportamental do consumidor (e.g., Hong et al., 2017; Hussain et al., 2019; Natarajan et al., 2018; Yang, 2005), indicando um *gap* em relação ao comportamento efetivo. Distintos estudos evidenciaram que há influência (direta e/ou indireta) do grau de inovatividade do consumidor na intenção, por exemplo, de adoção (e.g., Cheng & Huang, 2013; Yang, 2005; Zhang et al., 2012), uso (e.g. Anwar et al., 2020; Natarajan et al., 2017, 2018), continuidade de uso (e.g. Lu, 2014) e envolvimento (e.g. Kamboj & Gupta, 2020; Morosan & DeFranco, 2016) com aplicativos de distintas categorias. De modo geral, esses estudos sugerem que indivíduos mais inovadores tendem a lidar melhor com a incerteza, são mais dispostos a correr riscos e tendem a ter um maior nível de conforto com o uso da tecnologia. E, por conseguinte, um maior grau de inovatividade aumentaria a probabilidade de intenção de adoção e uso de novos aplicativos e/ou novos recursos incrementais.

Estudos anteriores demonstraram que a mensuração da capacidade de inovatividade específica do domínio tem revelado uma maior significância estatística de predição quando se pretende investigar um mercado em específico (e.g., Bartels & Reinders, 2011; Kaushik & Rahman, 2014; Lu et al., 2005). De acordo com o exposto, a presente pesquisa considerará a mensuração da inovatividade com base na inovatividade específica do domínio (Agarwal & Karahanna, 2000; Agarwal & Prasad, 1998), daqui em diante tratada como “inovatividade do consumidor”.

Estudos anteriores têm mensurado as variáveis de história de aprendizagem com os efeitos separados (e.g. Almeida et al., 2020; Foxall & Sigurdsson, 2013; Porto & Oliveira-Castro, 2013a, 2013b, 2015), considerando, contudo, que o efeito da experiência passada do consumidor pode resultar em perfis latentes não observados. O presente estudo pretende contribuir para o avanço da literatura sugerindo a proposição de perfis latentes de experiência mobile, em uma perspectiva analítica-comportamental. Nesta perspectiva, as variáveis sociodemográficas (e.g., sexo, idade e

ocupação) podem ser consideradas como covariantes do perfil latente, bem como o tamanho do repertório inicial de aplicativos por categoria (comportamental que indica preferências) e percepção de mudança comportamental decorrente da pandemia da Covid-19 (perceptiva de evento motivador) (Beaunoyer et al., 2020).

Considerando a perspectiva comportamental e os estudos mencionados com aplicativos que evidenciaram que o comportamento dos consumidores difere de acordo com seu nível de experiência mobile (evidência de moderação), propõe-se:

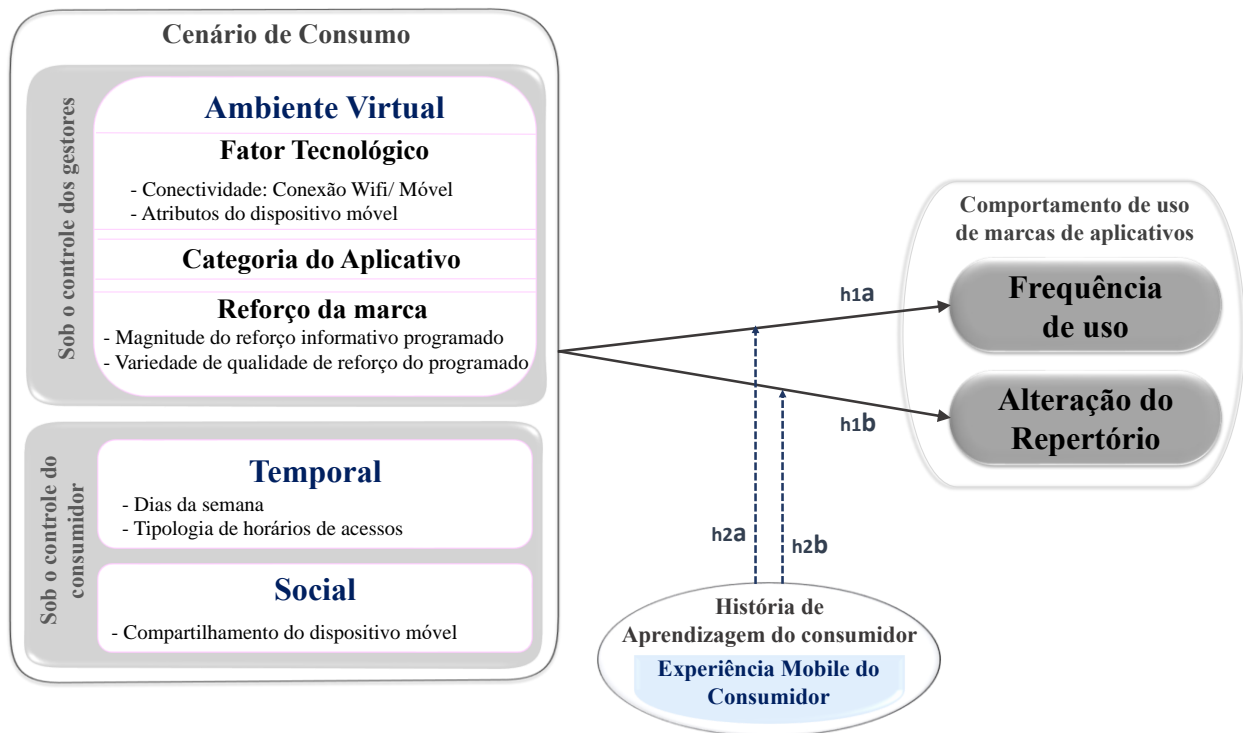
**H2a:** A experiência mobile do consumidor modera a relação da influência das variáveis do cenário de consumo sobre a frequência de uso de marcas de aplicativos.

**H2b:** A experiência mobile do consumidor modera a relação da influência das variáveis do cenário de consumo sobre a ocorrência de alteração de repertório de marcas de aplicativos.

A partir do referencial teórico e dos argumentos apresentados anteriormente, o modelo conceitual para este estudo é mostrado na Figura 8.

**Figura 8**

*Modelo Conceitual*





### **4.3 Métodos**

O presente estudo consiste em um experimento longitudinal em ambiente natural que visou estudar o comportamento real de uso de marcas de apps de consumidores em um país emergente. O experimento longitudinal é um tipo de quase-experimento no qual um grupo de indivíduos é monitorado ao longo do tempo, investigando possíveis variações no comportamento (variável dependente) em qualquer ponto no tempo ou detectando tendências, e é natural, por ser um estudo de campo no contexto real, sem intervenção dos pesquisadores. Em outras palavras, os dados emergidos são totalmente orgânicos (Viglia et al., 2021).

#### ***4.3.1 Amostra***

Para o alcance do objetivo proposto e testar as hipóteses, considerou-se um subconjunto de dados provenientes do banco de dados do projeto de pesquisa “M-Behavior” (ver Apêndice A). Esse subconjunto de dados era composto por medições de 126 dispositivos Android de consumidores do Centro-Oeste do Brasil com 28 dias ou mais de registro de atividades de uso de aplicativos. Considerando o nível de análise por consumidor e por dia, algumas informações necessárias para as análises não estavam disponíveis para todos os indivíduos. Portanto, foram excluídos do painel 25 consumidores.

Assim, o painel final é constituído por 101 consumidores e inclui um total de 286.110 registros de acessos padronizados a aplicativos de quatro categorias (Comunicação, Educação, Saúde & Fitness e Social), distribuídos em 3.030 pontos de registros.

#### ***4.3.2 Tratamento e análise dos dados***

Na Figura 9 são apresentadas as definições operacionais e as estatísticas descritivas das variáveis dependentes (VD1 – Frequência de uso de marcas de aplicativos e VD2 – Alteração do repertório de marcas de aplicativos) e demais variáveis que integram o modelo da pesquisa. Referente às variáveis independentes que integram a análise da VD2, com exceção das atemporais (e.g., atributos e compartilhamento do dispositivo móvel), as demais foram mensuradas com base na VD1 devido a problemas de multicolinearidade. Assim, essas variáveis devem ser interpretadas como: a configuração do contexto de uso do dia com probabilidade de ocorrência de alteração do repertório.

**Figura 9**

*Grupos, subgrupos e nome de variáveis: suas codificações, designação e análise descritiva*

<b>Grupo</b>	<b>subgrupo</b>	<b>Variável</b>	<b>Codificação</b>	<b>DV</b>	<b>Análise descritiva</b>
Comportamento		<b>Frequência de uso de marcas de aplicativos</b>	Somatório total de acessos às marcas de aplicativos das quatro categorias por dia.	VD1	A frequência média de uso por dia foi de 94,43 (dp. 74,32) acessos.
Comportamento		<b>Alteração do repertório de marcas de aplicativos</b>	Ocorrência de alteração do repertório de marcas de aplicativos: (0) não ocorreram alterações no repertório do consumidor no dia. (1) ocorreram alterações no repertório do consumidor no dia.	VD2	62,38% dos consumidores alteraram pelo menos uma vez o seu repertório durante o período amostrado. As ocorrências de alterações refletem em 4,2% dos pontos de registros.
		<b>Conectividade</b>	Somatório de registros de acessos em Wifi dividido pelo somatório de registros de acessos em móvel no dia ( $\sum w / \sum m$ ).	VI	80,74% do uso e 86,72% das alterações de repertório de marcas de apps ocorreram em conexão Wifi.
	Fator Tecnológico	<b>Atributos do dispositivo móvel</b>	Em um primeiro momento foram realizadas a classificação de cada atributo (tamanho da tela, capacidade de armazenamento e de processamento do dispositivo) e a soma total de atributos por dispositivos. Posteriormente, foram classificadas em dois níveis: (0) dispositivos com baixos atributos. (1) dispositivos com altos atributos.	VI	62,38% dos consumidores possuíam dispositivos com baixos atributos.
Cenário de comportamento (estímulo sob o controle dos gestores)	Reforço informativo programado da marca	<b>Magnitude do reforço informativo programado</b>	As marcas de apps foram agrupadas em níveis de magnitude de reforço informativo (mensurado no Estudo 2). Para tanto, foi realizado um reescalonamento dos scores por meio do tercil com três classes ( <i>i.e.</i> , 1 – baixo; 2 – médio; e 3 – alto). Com base na VD1, foi contabilizado o quantitativo de marcas de apps de alto reforço informativo programado usadas por dia.	VI	Foram usados em média 5,16 (dp. 2,02) aplicativos por dia. Sendo que, em média, 94,04% dessas marcas de aplicativos eram de alto reforço informativo programado ( $\bar{X}=4,85$ , dp. 1,84).
		<b>Variedade de qualidade de reforço informativo programado</b>	As marcas de apps foram agrupadas em níveis de magnitude de reforço informativo ( <i>i.e.</i> , conforme descrito para VI – Magnitude do Reforço). E posteriormente, foi verificada a variedade de qualidade de reforço informativo programado das marcas de aplicativos usadas por dia:	VI	Em 74,39% do tempo foram usadas marcas de apps de apenas um nível de reforço programado, que corresponde a apenas marcas de alto reforço informativo programado; em 23,14% do tempo

			(1) Uso de marcas de apenas um nível de reforço. (2) Uso de marcas de dois níveis de reforço. (3) Uso de marcas dos três níveis de reforço		foram usadas de dois níveis de reforço; e em 2,48% do tempo foram usadas de três níveis de reforço.
	Categoria do aplicativo	Nível de uso da categoria do aplicativo	Com base na constatação do Estudo 1, de que algumas categorias apresentam uma participação de uso inferior a 1%. Optou-se pela consideração da proporção de uso diário de cada categoria, padronizada em dois níveis (definidos pelo 2º quartil): (0) Não houve uso da categoria. (1) Houve uma baixa proporção de uso na categoria y. (2) Houve uma alta proporção de uso na categoria y.	VI	A mediana da proporção de uso diário de cada categoria foi: Comunicação = 72,59 Social = 29,06 Educação = 3,45 Saúde & Fitness = 1,82
		Dias da semana	(0) Dias de semana – considerado de segunda-feira a sexta-feira. (1) Final de semana – sábado e domingo.	VI	72,41% dos pontos de registros foram de dias da semana.
Cenário de comportamento (estímulo sob o controle dos consumidores)	Temporal	Tipologia de horários de acessos	Foi realizada uma análise de Clusters para a proposição de uma tipologia de configuração de intensidade de acesso ao longo do dia. Considerando os critérios de análise foram identificados três clusters que melhor representam a proporção de frequência de acessos por dia, independentemente do consumidor (ver detalhes no Apêndice F). Considerando que o padrão do Cluster 1 predominou em 60% do período, optou-se por testar o seu impacto quando comparado com os dois outros clusters sobre a VD1.	VI	Cluster 1 – Padrão Alvorada (60,3%) Cluster 2 – Padrão Vespertino (31,5%) Cluster 3 – Padrão Noturno (8,3%)
	Social	Compartilhamento do dispositivo móvel	(0) dispositivo não compartilhado – corresponde ao indivíduo que declarou, via questionário, que outras pessoas não usam seu dispositivo. (1) dispositivo compartilhado – corresponde ao indivíduo que declarou, via questionário, que outras pessoas usam seu dispositivo (independente da frequência de uso desses outrem).	VI	36,63% dos consumidores declararam que compartilham seus dispositivos móveis com outras pessoas.
História de Aprendizagem do consumidor		Experiência Mobile do Consumidor	Foi proposta uma análise de perfil latente de experiência mobile, que resultou em dois perfis (ver detalhes no Apêndice G): (0) menos experientes. (1) mais experientes.	VM	57,8% dos consumidores foram classificados como possuindo um perfil mais experiente.

*Legenda:* (DV) Designação da Variável – (VD1) Variável Dependente (Análise 1); (VD2) Variável Dependente (Análise 2); (VI) Variável Independente; (VM) Variável Moderadora

Em uma estrutura de painel estático com efeito fixo tem-se os consumidores como as variáveis sujeito (i) e os dias (t) como variáveis intra-sujeitos (Gujarati & Porter, 2011). O estudo possuiu duas variáveis dependentes, oito variáveis independentes e uma variável moderadora. Ao todo, foram elaborados quatro modelos estatísticos de teste, dois para cada variável dependente.

Inicialmente, desenvolveu-se o modelo de mínimos quadrados ordinários combinados para cada variável dependente com todas as variáveis independentes. Eles foram os modelos básicos de referência para decisão do melhor modelo estatístico. Verificou-se que a variância do modelo entre indivíduos é menor que intra e, pelo teste de *lagrange multiplier de Breusch-Godfrey*, rejeitou-se a hipótese nula que o modelo de MQO agrupado (*pooled*) é mais adequado ( $p \leq 0,05$ ), validando pela hipótese alternativa que o de efeitos aleatórios é mais apropriado. Posteriormente, pelo teste de *Hausman*, identificou-se que o de efeitos fixos é o correto ( $p \leq 0,05$ ), pois rejeitou-se a hipótese nula que entre efeitos fixos e efeitos aleatórios o melhor seria o estimador de efeitos aleatórios. O modelo não apresenta multicolinearidade pelo teste ( $VIF < 4$ ), porém foi diagnosticado pelo teste de *White* que o modelo tem problema de heterocedasticidade ( $p \leq 0,05$ ). Em pesquisa comportamental em ambiente natural dados não normalmente distribuídos com uma estrutura complicada são comuns (Pekár & Brabec, 2018). Dessa forma, optou-se pela realização de Equações de estimação generalizadas (GEE), uma regressão semi-paramétrica para dados longitudinais que oferece uma estimativa média da população para cada variável com a amostra utilizada (Ballinger, 2004; Zeger et al., 1988).

Para a variável dependente frequência de uso (VD1), que era contínua, regressões de Poisson GEE foram realizadas. E para a variável dependente alteração do repertório (VD2), que era binária, foram realizadas regressões logísticas GEE com função *logit*. A seleção da melhor matriz de correlação de trabalho e adequação dos modelos com o GEE foram avaliadas pela quase-verossimilhança sob o critério do modelo de independência (QIC), comparando-as com modelos alternativos (Pan, 2001). O QIC é análogo à conhecida estatística AIC (*Akaike's Information Criterion*) usada para comparar ajustes de modelos com métodos baseados em verossimilhança (Hardin & Hilbe, 2013).

## 4.4 Resultados

Para apresentação dos resultados dividiu-se os subtópicos de modo a apresentá-los em cada um dos testes feitos com as variáveis dependentes frequência de uso (VD1) e alteração do repertório (VD2).

### 4.4.1 Frequência de Uso

Utilizou-se o critério QIC para escolher a melhor matriz de correlação de trabalho. A melhor estrutura de correlação de trabalho na regressão de Poisson é aquela com o menor valor de QIC. Conforme pode ser observado na Tabela 4, os modelos apresentaram um bom ajuste (QIC e QICC inferiores ao nível de referência - modelo apenas com o intercepto).

**Tabela 4**

*Resultados das estimativas e dos ajustes para os modelos de frequência de uso de marca de aplicativos*

Variáveis independentes	Modelo 1 sem interação			Modelo 2 com interação		
	$\beta$	E.P.	Sig	$\beta$	E.P.	Sig
Intercepto	3,089	0,171	0,000***	2,730	0,193	0,000***
Conectividade	0,003	0,000	0,000***	0,003	0,000	0,000***
Atributos do Smartphone	0,101	0,089	0,263	0,100	0,085	0,250
Categoria do aplicativo						
Comunicação	0,049	0,065	0,491	0,042	0,063	0,510
Educação	-0,092	0,045	0,042*	-0,092	0,044	0,034*
Saúde & Fitness	-0,059	0,042	0,219	-0,057	0,038	0,135
Social	0,121	0,050	0,016*	0,118	0,046	0,010**
Reforço informativo programado da marca						
Magnitude do reforço (Nível alto)	0,178	0,016	0,000***	0,248	0,021	0,000***
Variedade da qualidade de reforço	0,174	0,055	0,002**	0,176	0,053	0,001**
Dia da semana	-0,093	0,033	0,005**	-0,090	0,032	0,005**
Tipologia de horário de acessos						
quando Padrão Alvorada (Cluster 1)	0,129	0,039	0,001***	0,122	0,038	0,001***
Compartilhamento do dispositivo móvel	-0,017	0,096	0,863	-0,015	0,094	0,872
Experiência Mobile do Consumidor	-0,122	0,091	0,181	0,498	0,194	0,010**
Magnitude do reforço informativo programado x Experiência Mobile do Consumidor				-0,114	0,026	0,000***
<b>R<sup>2</sup> Nagelkerke's</b>	45,8%			48,0%		
<b>QIC</b> (referência= 163947,0)	104540,6			101362,8		
<b>QICC</b> (referência= 162067,3)	98824,4			95865,0		

*Nota.*  $\beta$  = estimativa; E.P. = erro padrão; Sig. = grau de significância; \*  $p \leq 0,05$ ; \*\*  $p \leq 0,01$ ; \*\*\*  $p \leq 0,001$

Para o modelo 1 (efeitos principais), tanto os estímulos discriminativos sob o controle relativo de gestores quanto sob o controle relativo do consumidor mostraram-se preditores da frequência de uso de marcas de aplicativos, com peso total maior para o primeiro conjunto de variáveis independentes do que para o segundo. A magnitude ( $\beta = 0,178$ ,  $p \leq 0,001$ ) e variedade da qualidade ( $\beta = 0,174$ ,  $p \leq 0,01$ ) do reforço informativo programado, tipologia de horário de acessos ( $\beta = 0,129$ ,  $p \leq 0,01$ ), categoria de social ( $\beta = 0,121$ ,  $p \leq 0,05$ ), dia da semana ( $\beta = -0,093$ ,  $p \leq 0,01$ ), categoria de educação ( $\beta = -0,092$ ,  $p \leq 0,05$ ) e conectividade ( $\beta = 0,003$ ,  $p \leq 0,001$ ) foram preditores significativos, em ordem de impacto respectivamente.

Os resultados apontaram que os estímulos sob o controle de gestores da marca – magnitude ( $\beta = 0,178$ ,  $p \leq 0,001$ ) e amplitude de variedade da qualidade ( $\beta = 0,174$ ,  $p \leq 0,01$ ) do reforço informativo programado – possuem relação positiva com o comportamento, demonstrando que a cada aumento de uma marca de alta magnitude de reforço inclusa no repertório de uso aumentaria em 19,5% a frequência de uso de aplicativos, assim como espera-se que ocorra um aumento de 12,9%, se houver um acréscimo de marcas com nível de reforço diferente (*i.e.*, médio e/ou baixo) no repertório de uso do consumidor do dia.

Contudo, o impacto de apps de alta magnitude de reforço informativo na frequência de uso depende da experiência mobile do consumidor, conforme evidenciado no modelo com interação (modelo 2 na Tabela 4), sugerindo que, caso o consumidor seja mais experiente, a cada acréscimo de app desse nível de reforço ( $\beta = -0,114$ ,  $p \leq 0,001$ ) em seu repertório de uso diário espera-se uma redução de 10,8% na frequência de uso em relação a um consumidor menos experiente.

Em relação à proporção de uso das categorias de apps, observou-se que quanto maior a proporção de uso no dia de marcas de apps da categoria de social ( $\beta = 0,121$ ,  $p \leq 0,05$ ) espera-se um aumento de 12,9% na frequência de uso. Por outro lado, em dias que há uma maior proporção de uso de apps da categoria de educação ( $\beta = -0,092$ ,  $p \leq 0,05$ ) espera-se que ocorra uma redução de 8,8% na frequência de acessos.


Em relação aos estímulos sob o controle do consumidor, o compartilhamento do dispositivo não apresentou relação significativa com a frequência de uso. Contudo, os estímulos temporais apresentaram-se significativos, revelando que a frequência de uso de apps esperada para dias com configuração de horário de acessos “Padrão Alvorada” ( $\beta = 0,129$ ,  $p \leq 0,01$ ) é de 13,8% maior do

que para dias com outro tipo de padrão de configuração (“Padrão Vespertino” ou “Padrão Noturno”). E aos finais de semana a frequência de uso é 8,9% menor do que se fosse durante a semana ( $\beta = -0,093$ ,  $p \leq 0,01$ ).

A Figura 10 demonstra o efeito preditivo principal (A –  $R^2$  Nagelkerke’s=45,8%;  $p < 0,001$ ) e com interação (B – Nagelkerke’s= 48,0%;  $p < 0,001$ ) das variáveis independentes sobre a frequência de uso de marcas de apps. Pode-se observar que os dados estão positivamente correlacionados.

**Figura 10**

*Predição da frequência de uso de marcas de aplicativos*



#### 4.4.2 Alteração do Repertório

As estimativas de parâmetros na Tabela 5 oferecem insights sobre a influência de variáveis situacionais na alteração do repertório de apps do consumidor. Os modelos estatísticos ajustaram os dados razoavelmente bem (QIC e QICC inferiores ao nível de referência - modelo apenas com o intercepto). No modelo 3 foi testado o efeito principal das variáveis independentes no comportamento, considerando o contexto de uso no dia. Observou-se que tanto as variáveis sob controle relativo dos gestores como as sob controle relativo dos consumidores mostraram-se significativas (preditoras) na alteração de repertório, com peso total maior para o segundo conjunto de variáveis independentes do que para o primeiro.

**Tabela 5***Resultados das estimativas e dos ajustes para os modelos de alteração do repertório de marcas de aplicativos*

Variáveis independentes	Modelo 3 sem interação			Modelo 4 com interação		
	$\beta$	E.P.	Sig	$\beta$	E.P.	Sig
Intercepto	4,195	0,786	0,000***	5,897	1,093	0,000***
Conectividade	0,002	0,001	0,161	0,002	0,001	0,145
Atributos do Smartphone	0,368	0,239	0,124	0,373	0,238	0,117
Categoria do aplicativo						
Comunicação	0,152	0,361	0,674	0,100	0,369	0,787
Educação	0,111	0,176	0,529	0,105	0,173	0,544
Saúde & Fitness	0,197	0,145	0,173	0,201	0,151	0,185
Social	-0,097	0,258	0,705	-0,119	0,264	0,652
Reforço informativo programado da marca						
Magnitude do reforço (Nível alto)	-0,114	0,064	0,074	-0,111	0,064	0,081
Variedade da qualidade de reforço	-1,007	0,244	0,000***	-1,853	0,428	0,000***
Dia da semana	0,154	0,213	0,470	-0,500	0,403	0,215
Tipologia de horário de acessos						
Cluster 1 – Padrão Alvorada	0,704	0,277	0,011**	0,666	0,402	0,018**
Cluster 2 – Padrão Vespertino	0,889	0,312	0,004**	0,838	0,315	0,008**
Cluster 3 – Padrão Noturno	-			-		
Compartilhamento do dispositivo móvel	0,518	0,239	0,030*	-0,215	0,376	0,567
Experiência Mobile do Consumidor	-0,500	0,295	0,090	-2,555	0,816	0,002**
Variedade da qualidade de reforço x Experiência Mobile do Consumidor				1,076	0,445	0,016*
Dia da semana x Experiência Mobile do Consumidor				0,905	0,467	0,053*
Compartilhamento do dispositivo móvel x Experiência Mobile do Consumidor				0,901	0,469	0,054*
<b>R<sup>2</sup> Nagelkerke's</b>	8,0%			9,5%		
<b>QIC</b> (Referência= 1064,8)	1022,4			1014,9		
<b>QICC</b> (Referência= 1062,6)	1016,1			1008,1		

*Nota.*  $\beta$  = estimativa; E.P. = erro padrão; Sig. = grau de significância; \*  $p \leq 0,05$ ; \*\*  $p \leq 0,01$ ; \*\*\*  $p \leq 0,001$

Os resultados evidenciam que consumidores que compartilham o seu dispositivo móvel têm mais chances de apresentar alterações no seu repertório de apps do que aqueles que não compartilham ( $\beta=0,518$ , OR= 1,679,  $p \leq 0,05$ ). E há uma maior probabilidade de o indivíduo alterar o repertório em ocasiões com configurações de acessos “Padrão Alvorada” ( $\beta = 0,704$ , OR= 2,433,  $p \leq 0,01$ ) e “Padrão Vespertino” ( $\beta = 0,889$ , OR= 2,022,  $p \leq 0,01$ ) do que em ocasiões com configuração “Padrão Noturno”. Por outro lado, em dias com configurações que mais marcas de



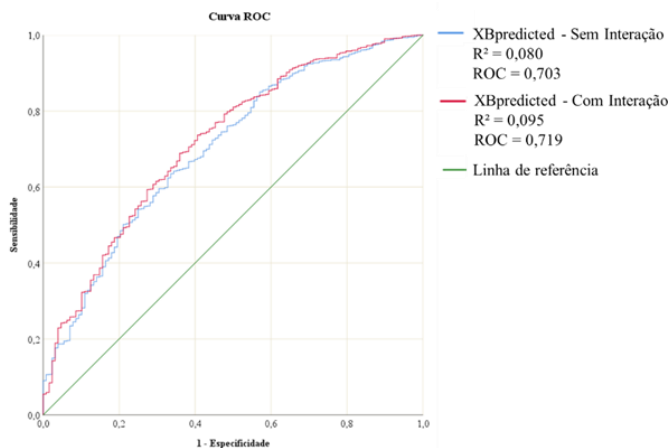
apps de diferentes qualidades de reforço programado são usadas ( $\beta = -1,007$ ,  $OR = 0,365$ ,  $p \leq 0,001$ ), menor será a probabilidade de o indivíduo alterar o seu repertório de apps.

No que tange a relação interativa (modelo 4 na Tabela 5) de variáveis do cenário de consumo com a experiência mobile do consumidor, constatou-se que quanto mais experiente o consumidor for e a configuração de uso de apps do dia for caracterizado por um repertório composto por marcas de diferentes qualidades de reforço informativo programado ( $\beta = 1,076$ ,  $OR = 2,932$ ,  $p \leq 0,01$ ), caso seja final de semana ( $\beta = 0,905$ ,  $p \leq 0,05$ ,  $OR = 2,473$ ) e ele compartilhe seu dispositivo móvel ( $\beta = 0,901$ ,  $OR = 2,461$ ,  $p \leq 0,05$ ), há uma maior probabilidade de ocorrer alteração do repertório de apps.

A experiência mobile do consumidor somente apresentaria influência direta significativa na alteração do repertório de marcas de apps ( $\beta = -2,555$ ,  $OR = 0,078$ ,  $p \leq 0,01$ ), em configuração de contexto de uso em que não houvesse variedade de qualidade de reforço informativo programado dos apps usados, caso não fosse final de semana e o indivíduo não compartilhasse o seu dispositivo móvel. Nesse caso, quanto menor a experiência do consumidor mobile, maior é a probabilidade de alteração do repertório. Análises da curva ROC foram realizadas com a finalidade de ter a representação geral dos resultados (ver Figura 11). Ela forneceu indicações de moderada probabilidade preditiva da alteração do repertório de marcas de aplicativos para ambos os modelos. Como um todo, o resultado sugere que o modelo com a interação da variável história de aprendizagem corrobora para um entendimento mais coeso do comportamento de alteração do repertório.

### Figura 11

*Curva ROC de ajuste dos modelos da alteração do repertório*



#### 4.5 Discussão dos resultados

Os resultados forneceram caminhos para a investigação do comportamento efetivo de uso de marcas – frequência de uso e alteração do repertório – e torna evidente que variáveis situacionais sob o controle relativo de gestores e de consumidores são suas preditoras. Contudo, a magnitude da predição desses conjuntos de variáveis varia dependendo do comportamento focal.

Os estímulos sob o controle de gestores apresentaram um impacto mais forte sobre a frequência de uso de apps (corroborando H1a). Em comparação, os principais influenciadores da frequência de uso foram os relacionados às funções reforçadoras contingentes à marca (Foxall, 1998a, 2004, 2016). Esse resultado corrobora os achados de pesquisas anteriores que utilizaram o arcabouço teórico-metodológico do BPM (Foxall, 1990, 2010) que demonstraram que os consumidores apresentam padrões de preferências em prol de marcas com maiores magnitudes de reforços (Foxall & James, 2003; Oliveira-Castro et al., 2016).

Por outro lado, para a ocorrência de alteração do repertório de marcas, os estímulos sob o controle relativo do consumidor foram, em conjunto, mais influentes do que os programados e controlados pelos gestores (refutando H1b). Além dos estímulos temporais, os resultados evidenciaram que estímulos sociais que abarcam o contexto *online-offline* podem estar associados com a ocorrência de alteração, corroborando com achados de estudos sobre escolha de marcas no âmbito offline (e.g., Almeida et al., 2020; Kachuba & Oliveira-Castro, 2020; Oliveira-Castro et al., 2011).

Em relação ao efeito de estímulo temporal (dias da semana e tipologia de acessos por dia), os resultados diferiram das tendências esperadas com base em estudos anteriores de que uma maior intensidade de uso (frequência e alterações) de apps estaria relacionada com horários não comerciais (Deng et al., 2019; Li et al., 2020a; Wang, 2020; Zhu et al., 2018), revelando uma possível nova tendência que ocorreu devido à pandemia – as pessoas integrando mais o mobile como ferramenta de trabalho e/ou estudo. Mais estudos se fazem necessários para confirmar se essa tendência se mantém em um período pós-pandêmico.

Os resultados evidenciam que os consumidores tendem a formar seus repertórios de preferências de uso, predominantemente, com marcas com maiores magnitudes de reforços, bem

como tendem a usar, na maior parte do tempo, um repertório de marcas no mesmo nível de reforço informativo, corroborando achados de estudos anteriores no contexto de compra (e.g., Foxall et al., 2004; Foxall & James, 2003; Oliveira-Castro et al., 2016; Porto & Oliveira-Castro, 2015).

Ao que tange a experiência mobile do consumidor, os resultados corroboraram H2a e H2b, demonstrando que a história de aprendizagem do consumidor modera a relação da influência das variáveis do cenário de consumo sobre a frequência de uso e a ocorrência de alteração de repertório de marcas de apps, revelando que o uso da marca de apps é resultante, portanto, de interação contínua entre contingências passadas e atuais (Foxall, 2016; Porto & Oliveira-Castro, 2013b). Os achados também apoiam estudos anteriores que evidenciaram que uma maior experiência aumenta a propensão da redução de barreiras de adoção e amplitude do uso de apps (Alam et al., 2020; Japutra et al., 2021; Kim et al., 2017; Natarajan et al., 2017; Son, 2017; Tam et al., 2020).

#### **4.6 Considerações finais**

Em ambos os aspectos metodológicos e teóricos, esta pesquisa contribui para a crescente literatura sobre o comportamento do consumidor no contexto mobile. Especificamente, respondendo ao chamado para dar mais atenção ao repertório de marcas de apps do consumidor para entender como os consumidores formam repertórios de diferentes tipos de apps e os consomem. A primeira contribuição diz respeito à aplicação do arcabouço teórico-metodológico do BPM na investigação do uso efetivo de marcas de apps, bem como demonstrando a pertinência de considerar uma estrutura analítica integrada que vincula dinamicamente antecedentes do nível agregado de análise da marca ou nível individual do comportamento de uso de marca do consumidor.

As descobertas apoiam e estendem padrões comportamentais em torno do repertório de marcas do consumidor do contexto de compra para o contexto de uso efetivo da marca, indicando que os consumidores tendem a formar seus repertórios de preferências de uso, predominantemente, com marcas com maiores magnitudes de reforços, bem como tendem a usar, na maior parte do tempo, um repertório de marcas no mesmo nível de reforço informativo.

Este estudo também reforça a literatura existente sobre as preferências de marca dos consumidores, fornecendo uma estrutura empírica que avaliou o efeito causal de variáveis

situacionais sobre a frequência de uso e alteração de repertório de marcas de apps. O presente estudo avança insights teóricos, integrando dados de campo em um ambiente da vida real e consumo de marcas, aumentando, assim, a eficácia dos resultados, demonstrando que a consideração do controle relativo de estímulos discriminativos pode contribuir para uma melhor previsão da força da influência a depender do comportamento focal de uso. Variáveis sob o controle relativo de gestores apresentaram uma influência conjunta mais forte sobre a frequência de uso de marcas de apps, enquanto as variáveis sobre o controle relativo do consumidor, em conjunto, foram preditores mais fortes da alteração do repertório de marcas.

Este estudo também avança pesquisas anteriores, que utilizaram o arcabouço teórico-metodológico do BPM, ao propor a mensuração do efeito conjunto de variáveis da história de aprendizagem do consumidor, partindo do pressuposto de que o efeito de experiências passadas dos consumidores pode resultar em perfis latentes não observados. Foram identificados dois perfis latentes de experiência mobile dos consumidores que se demonstraram moderadores da frequência de uso e alteração do repertório de apps.

Os achados deste estudo também apresentam implicações práticas para os profissionais da área ao evidenciar que a maior parcela das incidências de uso por dia, ao longo de 30 dias, envolveu marcas com alto nível de reforço informativo programado, revelando que os esforços de *branding* e aprimoramento constante do app, para que o consumidor continue a considerando como de alto reforço social, aumentariam as chances de a marca integrar o repertório de uso efetivo do consumidor.

A consideração da experiência mobile do consumidor auxiliaria para um entendimento mais completo das respostas comportamentais dos consumidores à marca. Por exemplo, o uso de marcas com variedades de qualidade de reforço informativo programado é prevalente entre os consumidores mais experientes. Esses, por sua vez, são caracterizados por possuírem maiores repertórios iniciais de diferentes níveis de reforço programado, maior tempo médio de uso de smartphones e apresentarem maiores scores de inovatividade. Em síntese, quanto maior a experiência mobile do consumidor maior seria a sua probabilidade de possuir repertório inicial de um maior quantitativo de categorias de apps, usar marcas de diferentes níveis de magnitudes de reforço informativo e alterar o seu repertório.

Semelhante a qualquer outro estudo de campo, este estudo tem certas limitações que podem oferecer algumas oportunidades para estudos futuros. Em primeiro lugar, o tamanho da amostra foi relativamente pequeno. Por mais que a pesquisa tenha adotado um delineamento de experimento longitudinal em ambiente natural e o conjunto de dados contivesse mais de 3.000 pontos de dados provenientes de 101 consumidores do Brasil, estudos futuros são encorajados a adotar tamanhos de amostra maiores de modo a testar se os resultados são persistentes. Em segundo lugar, apesar da abrangência de variáveis situacionais consideradas deste estudo, estudos futuros poderiam integrar outras variáveis situacionais, por exemplo, o reforço utilitário das marcas e mais categorias de apps. Em terceiro, estudos são motivados a conduzir experimento longitudinal mais extenso, de modo a capturar um maior quantitativo de pontos de registros de alteração do repertório de marcas de aplicativos. Por fim, estudos futuros poderiam considerar a proposta de perfis latentes de experiência mobile dos consumidores na investigação de outros comportamentos do consumidor no âmbito mobile, por exemplo, comportamento de compra.

## 5 Conclusão geral

A presente tese teve por objetivo estimar os padrões de desempenho e uso de marcas de aplicativos e seus antecedentes situacionais. Para alcançar esse objetivo amplo foram desenvolvidos três estudos em diferentes níveis de análises que se complementam, sendo cada estudo norteado por questões-chave de pesquisa em aberto na literatura que, por sua vez, possibilitaram delinear o projeto de pesquisa da tese. Esta tese reflete os dois lados da interação consumidor-marca no ecossistema mobile, combinando novos painéis de dados que refletem a perspectiva/ações das marcas (nível agregado – Estudos 1 e 2) e os comportamentos/respostas dos consumidores mobile (nível desagregado – Estudo 3).

Em conjunto, os estudos que integram a tese revelaram que, dada algumas particularidades, os padrões encontrados no contexto de compra da marca se estendem ao contexto de uso efetivo de marcas de bens digitais (apps). Assim, em uma visão macro, a contribuição desta tese foi a evidenciação de que muito do conhecimento e padrões em torno do comportamento de compra de marcas, se partir de fatos robustos como a premissa que os consumidores possuem repertório de marcas intra-categoria, podem auxiliar na compreensão do comportamento de uso efetivo de marcas e na relação consumidor-marca, lançando luz sob à robustez das abordagens de marketing baseado em evidência e de perspectiva comportamental para avançar o conhecimento no campo em acessão do mobile marketing.

Dada sua característica multidisciplinar, esta tese apresentou distintas contribuições teóricas e metodológicas. Ao que se refere a área de marketing, contribuiu-se para o avanço e extensão das abordagens de marketing baseado em evidências e de perspectiva comportamental, para o contexto de uso efetivo de marcas, em especial considerando marcas de bens digitais (aplicativos), resultando em insights sobre a relação consumidor-repertório de marca em diferentes estágios de interação e níveis de análises.

E, em particular, a tese contribui para a literatura de mobile marketing, campo do marketing em ascensão que abrange a gestão de marcas de apps, ao oferecer os primeiros insights em torno do desempenho e uso de marcas de apps e seus antecedentes situacionais com base em dados de painéis.

A principal contribuição do Estudo 1 foi avançar e estender descobertas sobre padrões sistemáticos de escolha do consumidor e parâmetros de desempenho da marca no contexto de compra da marca para o contexto de uso efetivo da marca, por meio de extensão e replicação de generalizações empíricas de marketing, atendendo ao apelo crescente de estudiosos e editoriais de *journals* de alto fator de impacto para a consideração e integração de replicações diferenciadas em estudos de administração e, mais especificamente, na área de marketing (cf. Babin et al., 2021; Dau et al., 2021; Driesener et al., 2022; Ryan & A Tipu, 2022).

O Estudo 1 também contribuiu metodologicamente, propondo e testando medidas de desempenho de uso efetivo de marcas de apps com aporte nas premissas do modelo NBD-Dirichlet. Os resultados evidenciaram que padrões de desempenho de marcas de apps no contexto de uso efetivo não diferem substancialmente dos padrões da lei do duplo risco (DJ), compartilhamento das bases de consumidores (DoP) e repertório de marcas encontrados para marcas de outras categorias de bens no contexto de compra (Driesener & Rungie, 2022; Scriven et al., 2017; Sharp et al., 2012). Cabe ressaltar que neste estudo foi utilizado um modelo de ordem zero. Logo, o feito de nenhuma variável foi controlado. Mesmo sem o controle de  $n$  variáveis (e.g., diferentes tipos de marcas de apps – pagas/gratuitas, nacionais/internacionais, funcionalidades; e contexto de obrigatoriedade ou não de uso do app), em linhas gerais, os padrões apresentaram-se consistentes com a literatura – generalizações propostas a mais de 50 anos.

Assim, o estudo contribui para a literatura de mobile marketing ao apresentar um panorama da estrutura de mercado de marcas de aplicativos, bem como ao explicar condições de contorno do conhecimento. Os resultados aqui apresentados poderão ser considerados como parâmetros comparativos para estudos futuros no contexto de uso efetivo de marcas.

Nos Estudos 2 e 3 demonstrou-se que a abordagem comportamental auxilia com maestria na interpretação de possíveis antecedentes situacionais, seja do desempenho de marcas (nível agregado) seja do comportamento do consumidor (nível desagregado da marca). Em uma visão ampla, os resultados dos estudos demonstraram a pertinência de relacionar antecedentes do nível agregado de análise da marca (desempenho de marcas) ao nível individual do comportamento de consumo de marcas do consumidor. Ratificando, assim, o elucidado por estudos sob a perspectiva comportamental, referente a pertinência de relacionar antecedentes do nível individual do comportamento do consumidor ao nível agregado de análise da marca para avançar no

entendimento de tais fenômenos, com auxílio de um mesmo arcabouço teórico (Foxall et al., 2021; Oliveira-Castro et al., 2008; Porto & Oliveira-Castro, 2015).

O Estudo 2 expandiu o Estudo 1 ao considerar explicar o que poderia impulsionar os resultados de desempenho competitivo de marcas de apps. Com base em achados de estudos comportamentais, questionou-se qual seria o efeito da força da marca sobre o desempenho de marcas de apps nos estágios de adoção e uso efetivo de marcas e se esse efeito variaria de acordo com a categoria do app. Para tanto, foi proposta uma métrica de força da marca equivalente à proposta por Oliveira-Castro et al. (2008), porém que ampliasse a abrangência do contexto competitivo das marcas. As medidas que compõem a métrica (familiaridade e qualidade percebida da marca) foram avaliadas e validadas quanto a sua relevância teórica e pertinência prática por cientistas de marketing e especialistas de tecnologia. A métrica foi criada a partir de metadados de uma loja de apps.

Os resultados corroboraram com estudos anteriores que investigaram esse impacto no contexto de compra da marca (e.g., Oliveira-Castro et al., 2008; Porto & Lima, 2015; Porto & Silva, 2014), demonstrando que, em geral, esse impacto é significativo e positivo, mas que varia de acordo com a categoria do bem (evidência de moderação).

Evidenciou-se, também, que no estágio de adoção esse impacto é mais forte, em especial para marcas de apps posicionadas em quantis mais altos de penetração por aquisição, corroborando com os achados de Porto e Lima (2015). No estágio de uso efetivo, o impacto da força da marca sobre o indicador de lealdade comportamental foi mais expressivo. Porém, não foi possível verificar se essa tendência era similar no contexto de compra de marcas, uma vez que não foram encontrados estudos sob a perspectiva comportamental com investigações explícitas dessa relação.

Uma vez elucidado o panorama competitivo de marcas de apps no contexto de uso efetivo de marcas, no Estudo 3 considerou-se pertinente e complementar para o avanço do conhecimento da relação consumidor-marca a investigação dos antecedentes situacionais do comportamento de uso da marca de apps no nível desagregado da marca, em que é incipiente investigações com base em dados comportamentais (Gera et al., 2020; Stocchi et al., 2021).

Os resultados revelaram que a consideração da perspectiva comportamental sobre o controle relativo sob os estímulos discriminativos (Foxall, 1998b; Foxall et al., 2013) auxiliou para um entendimento mais coeso de quais estímulos e quando são mais influentes sobre o



comportamento de uso de marcas de apps, evidenciando que tanto variáveis situacionais sob o controle relativo do consumidor quanto de gestores influenciam o comportamento de uso da marca, sendo o primeiro com um impacto mais forte sobre a ocorrência de alteração do repertório e o segundo com um impacto mais forte sobre a frequência de uso. Contudo, a influência dessas variáveis pode diferir conforme a experiência mobile do consumidor.

Os resultados corroboraram e fortaleceram a tese da abordagem de perspectiva comportamental de que os consumidores formam repertórios de preferência de marcas, em geral, com marcas que fornecem esquemas de reforçamento mais ricos (benefícios) (Cavalcanti et al., 2013; Foxall, 2004; Kachuba & Oliveira-Castro, 2020; Oliveira-Castro & Foxall, 2017; Oliveira-Castro et al., 2008; Porto & Oliveira-Castro, 2015). Este estudo contribui, assim, para esse fluxo de pesquisas ao estender padrões comportamentais de preferências dos consumidores, bem estabelecidos na literatura, para um novo contexto.

Embora o grande potencial que os dados digitais podem apresentar para múltiplas direções para avançar nas teorias e práticas de marketing, vale ressaltar que seu uso também apresenta consideráveis desafios relacionados à dispersão de dados, qualidade de dados, sua eficácia para medir fenômenos não observados; e conversão em medidas mercadológicas interpretáveis/comparáveis (Borges et al., 2021; Hair & Sarstedt, 2021). Levando tais aspectos em consideração, a presente tese contribui para profissionais da área e cientistas de marketing, ao demonstrar tratativas para a conversão de dados não-estruturados e metadados em medidas mercadológicas comparáveis e interpretáveis com base em abordagens robustas, contribuindo, assim, também para aproximação da academia e o mercado.

Em conjunto, os resultados dos três estudos apresentam implicações práticas para gestores de marcas de apps e que podem ser de interesse de outros atores do ecossistema mobile. Em síntese, ao fornecer: i) benchmarks iniciais da dinâmica competitiva de aplicativos, além do contexto da loja de apps; ii) direcionamentos que podem contribuir para insights de estratégias de vantagem competitiva para as marcas; iii) mecanismos para mensuração e monitoramento da força da marca de apps em relação à dinâmica do mercado; e iv) insights da interação consumidor-repertório de marca no contexto de uso efetivo.

Com base nos resultados discutidos no Estudo 1, gestores de marcas de apps recebem benchmarks iniciais acerca da dinâmica competitiva de marcas de apps para tomada de decisões

mais realistas, de acordo com os resultados de desempenho que seriam normais para uma marca do seu tamanho. Por exemplo, gestores de marcas de apps pequenas (menor penetração) devem perceber que é normal que seus consumidores também usem marcas de apps maiores (maior penetração) da categoria; se eles esperam que seus consumidores sejam integralmente leais a suas marcas, eles podem planejar e implementar estratégias de marketing inviáveis. Além desses resultados, este estudo identificou possíveis partições de mercado (desvios de DoP), evidenciando maior (ou menor) compartilhamento entre as marcas de apps do que o esperado. Esse nível de detalhe é importante, pois reconhecer esses desvios pode ajudar aos gerentes a compreender melhor com quais outras marcas de app intra-categoria eles estão compartilhando sua base de consumidores e, por conseguinte, se essas marcas são concorrentes ou atuam como complementares.

Os resultados discutidos no Estudo 2 fornecem aos gestores de apps insights acerca dos parâmetros da métrica de força da marca para o monitoramento dos resultados de desempenho das marcas, seja para avaliar o quão forte a marca é em relação as concorrentes intra-categoria, seja para avaliar o impacto dessa força em indicadores competitivos (teste de mercado) nos estágios de adoção e/ou de uso efetivo. Por exemplo, os gestores, ao estabelecerem metas/objetivos de marketing, podem tomar decisões mais realistas ao considerarem que raros são os casos em que uma marca de app ultrapassa dois desvios positivos em relação ao score médio da categoria; e que é de se esperar que a força da marca apresente um impacto mais forte sobre o desempenho da marca no estágio de adoção do que no estágio de uso efetivo. Já o Estudo 3 ofereceu aos gestores insights mais aguçados sobre os consumidores e seu comportamento de uso efetivo de marcas de apps (frequência de uso e alteração do repertório de marcas), como: que os consumidores tendem a formar seus repertórios de preferências de uso, predominantemente, com marcas com maiores magnitudes de reforços informativos; e que a consideração de modelos interativos com a experiência mobile do consumidor (fatores não gerenciáveis) auxiliaria para um entendimento mais completo das respostas comportamentais dos consumidores à marca.

No tocante à área de marketing, conforme constatado com base em revisões recentes da literatura que abarcam marcas de bens digitais (apps) e, de forma mais abrangente, o mobile marketing, esta pesquisa soma-se às primeiras tentativas de propor a estimativa de padrões de desempenho e uso de marcas de aplicativos e seus antecedentes situacionais, com base em dados

comportamentais com diferentes recortes temporais. Como tal, ela apresenta certas limitações que podem ser convertidas em caminhos para pesquisas futuras, conforme apresentadas em cada um dos estudos nos capítulos anteriores. De forma mais ampla, ao que tangencia os três estudos, vale mencionar as limitações em torno da natureza dos dados.

Sobre a natureza dos dados, conforme relatado por Stocchi et al. (2021), em revisão integrativa, ainda há um hiato entre cientistas de marketing e agentes do mercado mobile, o que resulta em barreiras expressivas para avançar o conhecimento do campo do mobile marketing com base em dados comportamentais com recorte longitudinal. A presente pesquisa procurou driblar essa barreira ao desenvolver e validar um aplicativo Android de monitoramento baseado em princípios de privacidade por design (mBehavior App) – que coletou dados declarados e comportamentais –, fornecendo aos pesquisadores cenários de investigação que se assemelham a configurações experimentais. Contudo, os dados considerados são restringidos: i) a um único sistema operacional (*i.e.*, sistema Android); ii) à região Centro-Oeste do Brasil; iii) a um recorte temporal de trinta dias – que condiz com um período pandêmico; iv) a um N amostral de consumidores relativamente pequeno. Pesquisas futuras são incentivadas a considerarem outros contextos como: dados de consumidores de dispositivos com sistema operacional (iOS), outras regiões territoriais, bem como que considerassem um maior quantitativo de consumidores e intervalo amostral intra-sujeitos para verificar se os resultados aqui encontrados são persistentes.

## Referências

- Aaker, D. A. (1996). Measuring Brand Equity Across Products and Markets. *California Management Review*, 38(3), 102–120. <https://doi.org/10.2307/41165845>
- Agarwal, R., & Karahanna, E. (2000). Time flies when you're having fun: Cognitive absorption and beliefs about information technology usage. *MIS Quarterly*, 24(4), 665–694. <https://doi.org/10.2307/3250951>
- Agarwal, R., & Prasad, J. (1998). A conceptual and operational definition of personal innovativeness in the domain of information technology. *Information Systems Research*, 9(2), 204–215. <https://doi.org/10.1287/isre.9.2.204>
- Aguinis, H., Hill, N. S., & Bailey, J. R. (2021). Best Practices in Data Collection and Preparation: Recommendations for Reviewers, Editors, and Authors. *Organizational Research Methods*, 24(4), 678–693. <https://doi.org/10.1177/1094428119836485>
- Al Ghamdi, E., Yunus, F., Da'ar, O., El-Metwally, A., Khalifa, M., Aldossari, B., & Househ, M. (2015). The effect of screen size on mobile phone user comprehension of health information and application structure: An experimental approach. *Journal of Medical Systems*, 40(1), 11. <https://doi.org/10.1007/s10916-015-0381-5>
- Alam, M. Z., Hu, W., Kaium, M. A., Hoque, M. R., & Alam, M. M. D. (2020). Understanding the determinants of mHealth apps adoption in Bangladesh: A SEM-Neural network approach. *Technology in Society*, 61, 101255. <https://doi.org/10.1016/j.techsoc.2020.101255>
- Almeida, M. I. S. de, Coelho, R. L. F., Porto, R. B., & Santos, J. A. (2020). Preditores da correspondência intenção-compra e dos níveis de reforço programado de marcas de especialidade. *ReMark - Revista Brasileira de Marketing*, 19(4), 738–761. <https://doi.org/10.5585/remark.v19i4.11126>
- Al-Nabhani, K., Wilson, A., & McLean, G. (2022). Examining consumers' continuous usage of multichannel retailers' mobile applications. *Psychology & Marketing*, 39(1), 168–195. <https://doi.org/10.1002/mar.21585>
- Anesbury, Z. W., Bennett, D., & Kennedy, R. (2022). How persistent are duplication of purchase partitions? *Journal of Consumer Behaviour*, 21(1), 137-152. <https://doi.org/10.1002/cb.1985>

- Anesbury, Z. W., Greenacre, L., Wilson, A. L., & Huang, A. (2018a). Patterns of fruit and vegetable buying behaviour in the United States and India. *International Journal of Market Research*, 60(1), 14–31. <https://doi.org/10.1177/1470785317751997>
- Anesbury, Z. W., Nguyen, Y., & Bogomolova, S. (2018b). Getting a “sweet” deal: Does healthfulness of a sub-brand influence consumer loyalty? *European Journal of Marketing*, 52(9/10), 1802–1826. <https://doi.org/10.1108/EJM-04-2017-0285>
- Anwar, A., Thongpapanl, N. (Tek), & Ashraf, A. R. (2020). Strategic imperatives of mobile commerce in developing countries: The influence of consumer innovativeness, ubiquity, perceived value, risk, and cost on usage. *Journal of Strategic Marketing*. <https://doi.org/10.1080/0965254X.2020.1786847>
- App Annie. (2017). *Spotlight on Consumer App Usage Part 1*. [http://files.appannie.com.s3.amazonaws.com/reports/1705\\_Report\\_Consumer\\_App\\_Usage\\_EN.pdf](http://files.appannie.com.s3.amazonaws.com/reports/1705_Report_Consumer_App_Usage_EN.pdf)
- App Annie. (2021). *State of Mobile 2021*. <https://www.appannie.com/en/go/state-of-mobile-2021/>
- AppsFlyer, & App Annie. (2021). *State of App Marketing Brazil 2021*. [https://go.appannie.com/202107-State\\_of\\_App\\_Marketing\\_Brazil\\_LP.html](https://go.appannie.com/202107-State_of_App_Marketing_Brazil_LP.html)
- Arya, V., Sethi, D., & Paul, J. (2019). Does digital footprint act as a digital asset? – Enhancing brand experience through remarketing. *International Journal of Information Management*, 49, 142–156. <https://doi.org/10.1016/j.ijinfomgt.2019.03.013>
- Babin, B. J., Moulard, J. G., & Lindquist, J. D. (2022). A bridge to relevance: On the history of the Academy of Marketing Science® (AMS). *AMS Review*, 11, 454-463. <https://doi.org/10.1007/s13162-021-00221-z>
- Babin, B. J., Ortinau, D. J., Herrmann, J.-L., & Lopez, C. (2021). Science is about corroborating empirical evidence, even in academic business research journals. *Journal of Business Research*, 126, 504–511. <https://doi.org/10.1016/j.jbusres.2020.06.002>
- Balapour, A., Reychav, I., Sabherwal, R., & Azuri, J. (2019). Mobile technology identity and self-efficacy: Implications for the adoption of clinically supported mobile health apps. *International Journal of Information Management*, 49, 58–68. <https://doi.org/10.1016/j.ijinfomgt.2019.03.005>

- Ballinger, G. A. (2004). Using Generalized Estimating Equations for Longitudinal Data Analysis. *Organizational Research Methods*, 7(2), 127–150.  
<https://doi.org/10.1177/1094428104263672>
- Banelis, M., Riebe, E., & Rungie, C. M. (2013). Empirical evidence of repertoire size. *Australasian Marketing Journal (AMJ)*, 21(1), 59–65.  
<https://doi.org/10.1016/j.ausmj.2012.11.001>
- Bandyopadhyay, S., & Martell, M. (2007). Does attitudinal loyalty influence behavioral loyalty? A theoretical and empirical study. *Journal of Retailing and Consumer Services*, 14(1), 35–44. <https://doi.org/10.1016/j.jretconser.2006.03.002>
- Bartels, J., & Reinders, M. J. (2011). Consumer innovativeness and its correlates: A propositional inventory for future research. *Journal of Business Research*, 64(6), 601–609.  
<https://doi.org/10.1016/j.jbusres.2010.05.002>
- Basole, R. C. (2009). Visualization of interfirm relations in a converging mobile ecosystem. *Journal of Information Technology*, 24(2), 144–159. <https://doi.org/10.1057/jit.2008.34>
- Basole, R. C., & Karla, J. (2011). On the Evolution of Mobile Platform Ecosystem Structure and Strategy. *Business & Information Systems Engineering*, 3(5), 313–322.  
<https://doi.org/10.1007/s12599-011-0174-4>
- Bass, F. M., & Wind, J. (1995). Introduction to the Special Issue: Empirical Generalizations in Marketing. *Marketing Science*, 14(3), G1–G5. <https://doi.org/10.1287/mksc.14.3.G1>
- Beaunoyer, E., Dupéré, S., & Guitton, M. J. (2020). COVID-19 and digital inequalities: Reciprocal impacts and mitigation strategies. *Computers in Human Behavior*, 111, 106424. <https://doi.org/10.1016/j.chb.2020.106424>
- Bellman, S., Potter, R. F., Treleaven-Hassard, S., Robinson, J. A., & Varan, D. (2011). The Effectiveness of Branded Mobile Phone Apps. *Journal of Interactive Marketing*, 25(4), 191–200. <https://doi.org/10.1016/j.intmar.2011.06.001>
- Bhattacharya, C. B. (1997). Is your brand's loyalty too much, too little, or just fight?" Explaining deviations in loyalty from the Dirichlet norm. *International Journal of Research in Marketing*, 14(5), 421–435. [https://doi.org/10.1016/S0167-8116\(97\)00024-4](https://doi.org/10.1016/S0167-8116(97)00024-4)
- Bijlani, A., Ramachandran, U., & Campbell, R. (2021). Where did my 256 GB go? A Measurement Analysis of Storage Consumption on Smart Mobile Devices. *Proceedings of*

- the ACM on Measurement and Analysis of Computing Systems*, 5(2), 28:1-28:28.  
<https://doi.org/10.1145/3460095>
- Biviji, R., Vest, J. R., Dixon, B. E., Cullen, T., & Harle, C. A. (2020). Factors Related to User Ratings and User Downloads of Mobile Apps for Maternal and Infant Health: Cross-Sectional Study. *JMIR MHealth and UHealth*, 8(1), e15663. <https://doi.org/10.2196/15663>
- Bogomolova, S., Anesbury, Z. W., Lockshin, L., Kapulski, N., & Bogomolov, T. (2019). Exploring the incidence and antecedents of buying an FMCG brand and UPC for the first time. *Journal of Retailing and Consumer Services*, 46, 121–129.  
<https://doi.org/10.1016/j.jretconser.2017.05.010>
- Borges, M., Bernardino, J., & Pedrosa, I. (2021). Data-driven decision making strategies applied to marketing. *2021 16th Iberian Conference on Information Systems and Technologies (CISTI)*, 1–7. <https://doi.org/10.23919/CISTI52073.2021.9476506>
- Bosmans, A. (2006). Scents and sensibility: When do (in)congruent ambient scents influence product evaluations? *Journal of Marketing*, 70(3), 32–43.  
<https://doi.org/10.1509/jmkg.70.3.032>
- Cable. (2019). *Worldwide broadband speed league 2019*. Cable.  
<https://www.cable.co.uk/broadband/speed/worldwide-speed-league/>
- Casas, P., Seufert, M., Wamser, F., Gardlo, B., Sackl, A., & Schatz, R. (2016). Next to you: Monitoring quality of experience in cellular networks from the end-devices. *IEEE Transactions on Network and Service Management*, 13(2), 181–196.  
<https://doi.org/10.1109/TNSM.2016.2537645>
- Casteran, G., Chrysochou, P., & Meyer-Waarden, L. (2019). Brand loyalty evolution and the impact of category characteristics. *Marketing Letters*, 30(1), 57–73.  
<https://doi.org/10.1007/s11002-019-09484-w>
- Cavalcanti, P. R., Oliveira-Castro, J. M. de, & Foxall, G. R. (2013). Individual differences in consumer buying patterns: A behavioral economic analysis. *The Psychological Record*, 63(2), 259–276. <https://doi.org/10.11133/j.tpr.2013.63.2.003>
- Chatfield, C., Ehrenberg, A. S. C., & Goodhardt, G. J. (1966). Progress on a Simplified Model of Stationary Purchasing Behaviour. *Journal of the Royal Statistical Society*, 129(3), 317–367.  
<https://doi.org/10.2307/2343502>

- Chen, Q., Lu, Y., Gong, Y., & Tang, Q. (2019). Why do users resist service organization's brand mobile apps? The force of barriers versus cross-channel synergy. *International Journal of Information Management*, 47, 274–282. <https://doi.org/10.1016/j.ijinfomgt.2018.07.012>
- Cheng, Y.-H., & Huang, T.-Y. (2013). High speed rail passengers' mobile ticketing adoption. *Transportation Research Part C: Emerging Technologies*, 30, 143–160. <https://doi.org/10.1016/j.trc.2013.02.001>
- Chiu, W., Cho, H., & Chi, C. G. (2021). Consumers' continuance intention to use fitness and health apps: An integration of the expectation–confirmation model and investment model. *Information Technology & People*, 34(3), 978–998. <https://doi.org/10.1108/ITP-09-2019-0463>
- Colombo, R. A., Ehrenberg, A. S. C., & Sabavala, D. (2000). Diversity in analyzing brand-switching tables: The car challenge. *Canadian Journal of Marketing Research*, 19, 23–36.
- Colombo, R. A., & Morrison, D. G. (1989). Note—A brand switching model with implications for marketing strategies. *Marketing Science*, 8(1), 89–99. <https://doi.org/10.1287/mksc.8.1.89>
- Corsi, A. M., Rungie, C., & Casini, L. (2011). Is the polarization index a valid measure of loyalty for evaluating changes over time? *Journal of Product & Brand Management*, 20(2), 111–120. <https://doi.org/10.1108/10610421111121107>
- Dau, L. A., Santangelo, G. D., & van Witteloostuijn, A. (2021). Replication studies in international business. *Journal of International Business Studies*, 53, 215–230. <https://doi.org/10.1057/s41267-021-00471-w>
- Davies, B. J., Kooijman, D., & Ward, P. (2003). The sweet smell of success: Olfaction in retailing. *Journal of Marketing Management*, 19(5–6), 611–627. <https://doi.org/10.1080/0267257X.2003.9728228>
- Dawes, J. (2008). Regularities in buyer behaviour and brand performance: The case of Australian beer. *Journal of Brand Management*, 15(3), 198–208. <https://doi.org/10.1057/palgrave.bm.2550099>
- Dawes, J. (2016a). Testing the robustness of brand partitions identified from purchase duplication analysis. *Journal of Marketing Management*, 32(7–8), 695–715. <https://doi.org/10.1080/0267257X.2015.1128961>



- Dawes, J. (2016b). Brand growth in packaged goods markets: Ten cases with common patterns. *Journal of Consumer Behaviour*, *15*(5), 475–489. <https://doi.org/10.1002/cb.1595>
- Dawes, J. (2018). Price promotions: Examining the buyer mix and subsequent changes in purchase loyalty. *Journal of Consumer Marketing*, *35*(4), 366–376. <https://doi.org/10.1108/JCM-03-2017-2134>
- Dawes, J., Bond, A., Hartnett, N., & Sharp, B. (2017). Does Double Jeopardy apply using average spend per buyer as the loyalty metric? *Australasian Marketing Journal (AMJ)*, *25*(4), 261–268. <https://doi.org/10.1016/j.ausmj.2017.10.008>
- Dawes, J., Graham, C., & Trinh, G. (2020). The long-term erosion of repeat-purchase loyalty. *European Journal of Marketing*, *55*(3), 763–789. <https://doi.org/10.1108/EJM-01-2018-0042>
- Dawes, J., Meyer-Waarden, L., & Driesener, C. (2015). Has brand loyalty declined? A longitudinal analysis of repeat purchase behavior in the UK and the USA. *Journal of Business Research*, *68*(2), 425–432. <https://doi.org/10.1016/j.jbusres.2014.06.006>
- Deng, T., Kanthawala, S., Meng, J., Peng, W., Kononova, A., Hao, Q., Zhang, Q., & David, P. (2019). Measuring smartphone usage and task switching with log tracking and self-reports. *Mobile Media & Communication*, *7*(1), 3–23. <https://doi.org/10.1177/2050157918761491>
- Dick, A. S., & Basu, K. (1994). Customer loyalty: Toward an integrated conceptual framework. *Journal of the Academy of Marketing Science*, *22*(2), 99–113. <https://doi.org/10.1177/0092070394222001>
- Ding, Y., DeSarbo, W. S., Hanssens, D. M., Jedidi, K., Lynch, J. G., & Lehmann, D. R. (2020). The past, present, and future of measurement and methods in marketing analysis. *Marketing Letters*, *31*(2–3), 175–186. <https://doi.org/10.1007/s11002-020-09527-7>
- Dinsmore, J., Swani, K., Goodrich, K., & Konus, U. (2021). Introduction: Advancing understanding of mobile applications in marketing. *Journal of Business Research*, *126*, 361–362. <https://doi.org/10.1016/j.jbusres.2021.01.005>
- Dowling, G., & Uncles, M. (1997). Do Customer Loyalty Programs Really Work? *Sloan Management Review*, *38*(4), 71–82.
- Driesener, C., Banelis, M., & Rungie, C. (2017). If the model fits, use it: Methods and benchmarks for evaluating NBD-Dirichlet goodness-of-fit. *Australasian Marketing Journal (AMJ)*, *25*(4), 288–293. <https://doi.org/10.1016/j.ausmj.2017.10.003>

- Driesener, C., & Rungie, C. (2022). The Dirichlet model in marketing. *Journal of Consumer Behaviour*, 21(1), 7-18. <https://doi.org/10.1002/cb.1975>
- Driesener, C., Rungie, C., & Wright, M. (2022). Dirichlet implications for portfolio management. *Journal of Consumer Behaviour*, 21(1), 49-62. <https://doi.org/10.1002/cb.1996>
- Ehrenberg, A. S. C. (1959). The pattern of consumer purchases. *Applied Statistics*, 8(1), 26–41. <https://doi.org/10.2307/2985810>
- Ehrenberg, A. S. C. (1988). *Repeat-buying: Facts, theory, and applications* (New ed). Griffin ; Oxford University Press.
- Ehrenberg, A. S. C. (1995). Empirical generalisations, theory, and method. *Marketing Science*, 14(3), G20–G28. <https://doi.org/https://doi.org/10.1287/mksc.14.3.G20>
- Ehrenberg, A. S. C., Barnard, N., Kennedy, R., & Bloom, H. (2002). Brand advertising as creative publicity. *Journal of Advertising Research*, 42(4), 7–18. <https://doi.org/10.2501/JAR-42-4-7-18>
- Ehrenberg, A., & Goodhardt, G. (1968a). A comparison of American and British repeat-buying habits. *Journal of Marketing Research*, 5, 29–33. <https://doi.org/10.1177/002224376800500103>
- Ehrenberg, A. S. C., & Goodhardt, G. J. (1968b). Incidence of Brand-Switching. *Nature*, 220, 304. <https://doi.org/10.1038/220304a0>
- Ehrenberg, A. S. C., & Goodhardt, G. J. (1970). A Model of Multi-Brand Buying. *Journal of Marketing Research*, 7(1), 77–84. JSTOR. <https://doi.org/10.2307/3149510>
- Ehrenberg, A. S. C., & Goodhardt, G. J. (2002). Double Jeopardy revisited, again. *Marketing Research*, 14(1), 40–41.
- Ehrenberg, A. S. C., Goodhardt, G. J., & Barwise, T. P. (1990). Double Jeopardy revisited. *Journal of Marketing*, 54(3), 82–91. JSTOR. <https://doi.org/10.2307/1251818>
- Ehrenberg, A. S. C., Hammond, K., & Goodhardt, G. J. (1994). The after-effects of price-related consumer promotions. *Journal of Advertising Research*, 34(4), 11–21.
- Ehrenberg, A. S. C., Uncles, M. D., & Goodhardt, G. J. (2004). Understanding brand performance measures: Using Dirichlet benchmarks. *Journal of Business Research*, 57(12), 1307–1325. <https://doi.org/10.1016/j.jbusres.2002.11.001>

- Fader, P. S., & Schmittlein, D. C. (1993). Excess behavioral loyalty for high-share brands: Deviations from the Dirichlet Model for repeat purchasing. *Journal of Marketing Research*, 30(4), 478–493. <https://doi.org/10.1177/002224379303000407>
- Fetscherin, M., & Heinrich, D. (2015). Consumer brand relationships research: A bibliometric citation meta-analysis. *Journal of Business Research*, 68(2), 380–390. <https://doi.org/10.1016/j.jbusres.2014.06.010>
- Finkelstein, A., Harman, M., Jia, Y., Martin, W., Sarro, F., & Zhang, Y. (2017). Investigating the relationship between price, rating, and popularity in the Blackberry World App Store. *Information and Software Technology*, 87, 119–139. <https://doi.org/10.1016/j.infsof.2017.03.002>
- Flaherty, S. J., McCarthy, M., Collins, A. M., McCafferty, C., & McAuliffe, F. M. (2021). Exploring engagement with health apps: The emerging importance of situational involvement and individual characteristics. *European Journal of Marketing*, 55(13), 122–147. <https://doi.org/10.1108/EJM-06-2019-0531>
- Floh, A., Zauner, A., Koller, M., & Rusch, T. (2014). Customer segmentation using unobserved heterogeneity in the perceived-value–loyalty–intentions link. *Journal of Business Research*, 67(5), 974–982. <https://doi.org/10.1016/j.jbusres.2013.08.003>
- Fogg, I. (2019). *How the Smartphone affects mobile network experience*. OpenSignal. [https://www.opensignal.com/sites/opensignal-com/files/data/reports/pdf-only/data-2019-08/smartphone\\_mobile\\_network\\_experience\\_august\\_2019.pdf](https://www.opensignal.com/sites/opensignal-com/files/data/reports/pdf-only/data-2019-08/smartphone_mobile_network_experience_august_2019.pdf)
- Fong, N. M., Fang, Z., & Luo, X. (2015). Geo-conquesting: Competitive locational targeting of mobile promotions. *Journal of Marketing Research*, 52(5), 726–735. <https://doi.org/10.1509/jmr.14.0229>
- Fox, J., & Weisberg, S. (2020). *car: Companion to Applied Regression* (R package). from <https://cran.r-project.org/package=car>
- Foxall, G. R. (1990). *Consumer psychology in behavioral perspective*. Beard Books.
- Foxall, G. R. (1992). The consumer situation: An integrative model for research in marketing. *Journal of Marketing Management*, 8(4), 383–404. <https://doi.org/10.1080/0267257X.1992.9964206>

- Foxall, G. R. (1998a). Intention versus Context in Consumer Psychology. *Journal of Marketing Management*, 14(1–3), 29–62. <https://doi.org/10.1362/026725798784959327>
- Foxall, G. R. (1998b). Radical behaviorist interpretation: Generating and evaluating an account of consumer behavior. *The Behavior Analyst*, 21(2), 321–354. <https://doi.org/10.1007/BF03391971>
- Foxall, G. R. (1999). Behaviorism. In P. E. Earl, & S. Kemp (Eds.), *The Elgar Companion to Consumer Research and Economic Psychology* (pp. 38–45). Edward Elgar.
- Foxall, G. R. (2004). *Context and Cognition: Interpreting Complex Behavior*. Context Press.
- Foxall, G. R. (2009). *Interpreting consumer choice: The Behavioural Perspective Model*. Routledge.
- Foxall, G. R. (2010). Theoretical and conceptual advances in consumer behavior analysis: Invitation to consumer behavior analysis. *Journal of Organizational Behavior Management*, 30(2), 92–109. <https://doi.org/10.1080/01608061003756307>
- Foxall, G. R. (Org.). (2015). *The Routledge companion to consumer behavior analysis*. Routledge.
- Foxall, G. R. (Org.). (2016). *Perspectives on consumer choice: From behavior to action, from action to agency*. Palgrave Macmillan. 10.1057/978-1-137-50121-9
- Foxall, G. R., Goldsmith, R. E., & Brown, S. (1998). *Consumer Psychology for Marketing*. Cengage Learning EMEA.
- Foxall, G. R., & James, V. K. (2003). The behavioral ecology of brand choice: How and what do consumers maximize? *Psychology & Marketing*, 20(9), 811–836. <https://doi.org/10.1002/mar.10098>
- Foxall, G. R., Oliveira-Castro, J. M. de, & Porto, R. B. (2021). Consumer behavior analysis and the marketing firm: Measures of performance. *Journal of Organizational Behavior Management*, 97–123. <https://doi.org/10.1080/01608061.2020.1860860>
- Foxall, G. R., Oliveira-Castro, J. M. de, & Schrezenmaier, T. C. (2004). The behavioral economics of consumer brand choice: Patterns of reinforcement and utility maximization. *Behavioural Processes*, 66(3), 235–260. <https://doi.org/10.1016/j.beproc.2004.03.007>

- Foxall, G. R., & Sigurdsson, V. (2013). Consumer Behavior Analysis: Behavioral Economics Meets the Marketplace. *The Psychological Record*, *63*(2), 231–238.  
<https://doi.org/10.11133/j.tpr.2013.63.2.001>
- Foxall, G. R., Yan, J., Oliveira-Castro, J. M. de, & Wells, V. K. (2013). Brand-related and situational influences on demand elasticity. *Journal of Business Research*, *66*(1), 73–81.  
<https://doi.org/10.1016/j.jbusres.2011.07.025>
- Foxall, G. R., & Yani-de-Soriano, M. M. (2005). Situational influences on consumers' attitudes and behavior. *Journal of Business Research*, *58*(4), 518–525. [https://doi.org/10.1016/S0148-2963\(03\)00142-5](https://doi.org/10.1016/S0148-2963(03)00142-5)
- Gera, R., Chadha, P., & Ahuja, V. (2020). Mobile app usage and adoption: A literature review. *International Journal of Electronic Business*, *15*(2), 160–195.  
<https://doi.org/10.1504/IJEB.2020.106546>
- Gokgoz, Z. A., Ataman, M. B., & Van Bruggen, G. H. (2021). There's an app for that! Understanding the drivers of mobile application downloads. *Journal of Business Research*, *123*, 423–437. <https://doi.org/10.1016/j.jbusres.2020.10.006>
- Goldsmith, R. E., & Foxall, G. R. (2003). The Measurement of Innovativeness. In L. V. Shavinina (Org.), *The International Handbook on Innovation* (p. 321–330). Pergamon.  
<https://doi.org/10.1016/B978-008044198-6/50022-X>
- Goodhardt, G. J., Ehrenberg, A. S. C., & Chatfield, C. (1984). The Dirichlet: A comprehensive model of buying behaviour. *Journal of the Royal Statistical Society. Series A (General)*, *147*(5), 621–655. JSTOR. <https://doi.org/10.2307/2981696>
- Google. (2020). *See your app's ratings & reviews*.  
<https://support.google.com/googleplay/android-developer/>
- Graham, C., Bennett, D., Franke, K., Henfrey, C. L., & Nagy-Hamada, M. (2017). Double Jeopardy – 50 years on. Reviving a forgotten tool that still predicts brand loyalty. *Australasian Marketing Journal (AMJ)*, *25*(4), 278–287.  
<https://doi.org/10.1016/j.ausmj.2017.10.009>
- Graham, C., Khan, K., & Ilyas, M. (2019). Estimating the value of passing trade from pedestrian density. *Journal of Retailing and Consumer Services*, *46*, 103–111.  
<https://doi.org/10.1016/j.jretconser.2017.10.005>

- Grasby, A., Corsi, A., Dawes, J., Driesener, C., & Sharp, B. (2021). How loyalty extends across product categories. *Journal of Consumer Behaviour*, 21(1), 153-163.  
<https://doi.org/10.1002/cb.1981>
- Grewal, D., Bart, Y., Spann, M., & Zubcsek, P. P. (2016). Mobile advertising: A framework and research agenda. *Journal of Interactive Marketing*, 34, 3–14.  
<https://doi.org/10.1016/j.intmar.2016.03.003>
- Guan, L., Peng, T.-Q., & Zhu, J. J. (2019). Who is tracking health on mobile devices: Behavioral logfile analysis in Hong Kong. *JMIR MHealth and UHealth*, 7(5), e13679.  
<https://doi.org/10.2196/13679>
- Gujarati, D. N., & Porter, D. C. (2011). *Econometria Básica* (5<sup>o</sup> ed). AMGH. McGraw-Hill.
- Habel, C., & Lockshin, L. (2013). Realizing the value of extensive replication: A theoretically robust portrayal of double jeopardy. *Journal of Business Research*, 66(9), 1448–1456. <https://doi.org/10.1016/j.jbusres.2012.05.012>
- Hair, J. F., & Sarstedt, M. (2021). Data, measurement, and causal inferences in machine learning: Opportunities and challenges for marketing. *Journal of Marketing Theory and Practice*, 29(1), 65–77. <https://doi.org/10.1080/10696679.2020.1860683>
- Hamerly, G., & Elkan, C. (2004). Learning the k in k-means. *Advances in Neural Information Processing Systems*, 16.  
<https://proceedings.neurips.cc/paper/2003/hash/234833147b97bb6aed53a8f4f1c7a7d8-Abstract.html>
- Hanssens, D. M., & Pauwels, K. H. (2016). Demonstrating the Value of Marketing. *Journal of Marketing*, 80(6), 173–190. <https://doi.org/10.1509/jm.15.0417>
- Hardin, J. W., & Hilbe, J. M. (2013). *Generalized estimating equations* (2<sup>o</sup> ed). Chapman & Hall Book/CRC.
- Hill, S. (2021, abril 24). *How Many GB of RAM Does a Smartphone Need? We Asked the Experts*. Digital Trends. <https://www.digitaltrends.com/mobile/how-much-ram-does-a-smartphone-need/>
- Hong, J.-C., Lin, P.-H., & Hsieh, P.-C. (2017). The effect of consumer innovativeness on perceived value and continuance intention to use smartwatch. *Computers in Human Behavior*, 67, 264–272. <https://doi.org/10.1016/j.chb.2016.11.001>

- Huang, Y.-C., Chang, L. L., Yu, C.-P., & Chen, J. (2019). Examining an extended technology acceptance model with experience construct on hotel consumers' adoption of mobile applications. *Journal of Hospitality Marketing & Management, 0*, 1–24.  
<https://doi.org/10.1080/19368623.2019.1580172>
- Hussain, S., Qazi, S., Ahmed, R. R., Vveinhardt, J., & Streimikiene, D. (2019). Innovative user engagement and playfulness on adoption intentions of technological products: Evidence from SEM-based multivariate approach. *Economic Research-Ekonomska Istraživanja, 32*(1), 555–577. <https://doi.org/10.1080/1331677X.2018.1558086>
- ISO 20671. (2021). *ISO 20671—Brand evaluation*. <https://www.iso.org/ics/03.140/x/>
- Jacoby, J., & Kyner, D. B. (1973). Brand loyalty vs. Repeat purchasing behavior. *Journal of Marketing Research, 10*(1), 1–9. <https://doi.org/10.1177/002224377301000101>
- Japutra, A., Utami, A. F., Molinillo, S., & Ekaputra, I. A. (2021). Influence of customer application experience and value in use on loyalty toward retailers. *Journal of Retailing and Consumer Services, 59*, 102390. <https://doi.org/10.1016/j.jretconser.2020.102390>
- John, J., & Thakur, R. (2021). Long term effects of service adaptations made under pandemic conditions: The new “post COVID-19” normal. *European Journal of Marketing, 55*(6), 1679–1700. <https://doi.org/10.1108/EJM-08-2020-0607>
- Ju, X., Martín Martín, O., & Chocarro, R. (2021). Determinants of mobile social media use, customer heterogeneity, and international microsegmentation. *International Journal of Consumer Studies, n/a*(n/a). <https://doi.org/10.1111/ijcs.12748>
- Kachuba, D., & Oliveira-Castro, J. M. de. (2020). Análise do comportamento de avaliação de marcas: Nível de reforço informativo programado e ponto de venda. *Perspectivas em Análise do Comportamento, 11*(1), 032–046. <https://doi.org/10.18761/PAC.2020.v11.n1.03>
- Kahn, B. E., Kalwani, M. U., & Morrison, D. G. (1988). Niching versus Change-of-Pace Brands: Using Purchase Frequencies and Penetration Rates to Infer Brand Positionings. *Journal of Marketing Research, 25*(4), 384–390. <https://doi.org/10.1177/002224378802500406>
- Kamboj, S., & Gupta, S. (2020). Use of smart phone apps in co-creative hotel service innovation: An evidence from India. *Current Issues in Tourism, 23*(3), 323–344.  
<https://doi.org/10.1080/13683500.2018.1513459>

- Kannan, P. K., & Li, H. A. (2017). Digital marketing: A framework, review and research agenda. *International Journal of Research in Marketing*, 34(1), 22–45.  
<https://doi.org/10.1016/j.ijresmar.2016.11.006>
- Kantar. (2020, maio). *Android vs. IOS – Smartphone OS sales market share evolution*. Kantar World Panel. <https://www.kantarworldpanel.com/smartphone-os-market-share/>
- Kantar. (2021, setembro). *Android vs. IOS – Smartphone OS sales market share evolution*. Kantar World Panel. <https://www.kantarworldpanel.com/smartphone-os-market-share/>
- Kaushik, A. K., & Rahman, Z. (2014). Perspectives and Dimensions of Consumer Innovativeness: A Literature Review and Future Agenda. *Journal of International Consumer Marketing*, 26(3), 239–263. <https://doi.org/10.1080/08961530.2014.893150>
- Kearns, Z. (2010). *Dirichlet.Xls*. Massey University.
- Keller, K. L. (1993). Conceptualizing, Measuring, and Managing Customer-Based Brand Equity. *Journal of Marketing*, 57(1), 1–22. <https://doi.org/10.1177/002224299305700101>
- Keller, K. L. (2020). Consumer Research Insights on Brands and Branding: A JCR Curation. *Journal of Consumer Research*, 46(5), 995–1001. <https://doi.org/10.1093/jcr/ucz058>
- Keller, K. L. (2021). The Future of Brands and Branding: An Essay on Multiplicity, Heterogeneity, and Integration. *Journal of Consumer Research*, 48(4), 527–540.  
<https://doi.org/10.1093/jcr/ucab063>
- Keller, K. L. (2022). Understanding the changing role and functions of marketing. Em *APA handbook of consumer psychology* (p. 143–162). American Psychological Association.  
<https://doi.org/10.1037/0000262-005>
- Keller, K. L., & Brexendorf, T. O. (2019). Measuring Brand Equity. In F.-R. Esch (Org.), *Handbuch Markenführung* (p. 1409–1439). Springer Fachmedien.  
[https://doi.org/10.1007/978-3-658-13342-9\\_72](https://doi.org/10.1007/978-3-658-13342-9_72)
- Kennedy, R., Scriven, J., & Nenycz-Thiel, M. (2014). When ‘Significant’ is not Significant. *International Journal of Market Research*, 56(5), 591–607. <https://doi.org/10.2501/IJMR-2014-041>
- Kim, J.-H., Sun, Y., & Wagman, L. (2021). *The Value of Technology Releases in the Mobile App Ecosystem: The economic impact of software developer kits* (p. 32). Data Catalyst Institute.



- <https://datacatalyst.org/wp-content/uploads/2021/01/The-Value-of-Technology-Releases-in-the-Mobile-App-Ecosystem-012921.pdf>
- Kim, M., Kim, J., Choi, J., & Trivedi, M. (2017). Mobile shopping through applications: Understanding application possession and mobile purchase. *Journal of Interactive Marketing, 39*, 55–68. <https://doi.org/10.1016/j.intmar.2017.02.001>
- Khamitov, M., Wang, X. S., & Thomson, M. (2019). How Well Do Consumer-Brand Relationships Drive Customer Brand Loyalty? Generalizations from a Meta-Analysis of Brand Relationship Elasticities. *Journal of Consumer Research, 46*(3), 435–459. <https://doi.org/10.1093/jcr/ucz006>
- Knoferle, K. M., Spangenberg, E. R., Herrmann, A., & Landwehr, J. R. (2012). It is all in the mix: The interactive effect of music tempo and mode on in-store sales. *Marketing Letters, 23*(1), 325–337. <https://doi.org/10.1007/s11002-011-9156-z>
- Koenker, R. (2017). Quantile Regression: 40 Years On. *Annual Review of Economics, 9*(1), 155–176. <https://doi.org/10.1146/annurev-economics-063016-103651>
- Koenker, R., & Hallock, K. F. (2001). Quantile Regression. *Journal of Economic Perspectives, 15*(4), 143–156. <https://doi.org/10.1257/jep.15.4.143>
- Lamberton, C., & Stephen, A. T. (2016). A Thematic exploration of digital, social media, and mobile marketing: Research evolution from 2000 to 2015 and an agenda for future inquiry. *Journal of Marketing, 80*(6), 146–172. <https://doi.org/10.1509/jm.15.0415>
- Lemon, K. N., & Verhoef, P. C. (2016). Understanding Customer Experience Throughout the Customer Journey. *Journal of Marketing, 80*(6), 69–96. <https://doi.org/10.1509/jm.15.0420>
- Li, H., Lu, X., Liu, X., Xie, T., Bian, K., Lin, F. X., Mei, Q., & Feng, F. (2015). Characterizing Smartphone Usage Patterns from Millions of Android Users. *Proceedings of the 2015 Internet Measurement Conference, 459–472*. <https://doi.org/10.1145/2815675.2815686>
- Li, T., Li, Y., Hoque, M. A., Xia, T., Tarkoma, S., & Hui, P. (2020a). To What Extent We Repeat Ourselves? Discovering Daily Activity Patterns Across Mobile App Usage. *IEEE Transactions on Mobile Computing, 1–1*. <https://doi.org/10.1109/TMC.2020.3021987>
- Li, T., Zhang, M., Cao, H., Li, Y., Tarkoma, S., & Hui, P. (2020b). What Apps Did You Use?: Understanding the Long-term Evolution of Mobile App Usage. *Proceedings of The Web Conference 2020, 66–76*. <https://doi.org/10.1145/3366423.3380095>

- Lindgren, R., Eriksson, O., & Lyytinen, K. (2015). Managing Identity Tensions during Mobile Ecosystem Evolution. *Journal of Information Technology*, 30(3), 229–244.  
<https://doi.org/10.1057/jit.2015.8>
- Lindsay, R. M., & Ehrenberg, A. S. C. (1993). The Design of Replicated Studies. *The American Statistician*, 47(3), 217–228. <https://doi.org/10.1080/00031305.1993.10475983>
- Linzer, D. A., & Lewis, J. B. (2011). PoLCA: an R package for polytomous variable latent class analysis. *Journal of Statistical Software*, 42(10), 1–29. <https://doi.org/10.18637/jss.v042.i10>
- Linzer, D. A., & Lewis, J. B. (2021). *PoLCA: An R Package for Polytomous Variable Latent Class Analysis* (R package). <https://CRAN.R-project.org/package=poLCA>
- Liu, C. Z., Au, Y. A., & Choi, H. S. (2014). Effects of Freemium strategy in the Mobile App Market: An empirical study of Google Play. *Journal of Management Information Systems*, 31(3), 326–354. <https://doi.org/10.1080/07421222.2014.995564>
- Lu, J. (2014). Are personal innovativeness and social influence critical to continue with mobile commerce? *Internet Research*. <https://doi.org/10.1108/IntR-05-2012-0100>
- Lu, J., Yao, J. E., & Yu, C.-S. (2005). Personal innovativeness, social influences and adoption of wireless Internet services via mobile technology. *The Journal of Strategic Information Systems*, 14(3), 245–268. <https://doi.org/10.1016/j.jsis.2005.07.003>
- Lynn, M. R. (1986). Determination and quantification of content validity. *Nursing Research*, 35(6), 382–385. <https://doi.org/10.1097/00006199-198611000-00017>
- Manlove, J., & Whitacre, B. (2019). Understanding the trend to mobile-only internet connections: A decomposition analysis. *Telecommunications Policy*, 43(1), 76–87.  
<https://doi.org/10.1016/j.telpol.2018.03.012>
- Masi, A. D., & Wac, K. (2019). Predicting quality of experience of popular mobile applications from a living lab study. *2019 Eleventh International Conference on Quality of Multimedia Experience (QoMEX)*, 1–6. <https://doi.org/10.1109/QoMEX.2019.8743306>
- McLean, G. (2018). Examining the determinants and outcomes of mobile app engagement - A longitudinal perspective. *Computers in Human Behavior*, 84, 392–403.  
<https://doi.org/10.1016/j.chb.2018.03.015>

- McLean, G., Al-Nabhani, K., & Wilson, A. (2018). Developing a Mobile Applications Customer Experience Model (MACE)- Implications for retailers. *Journal of Business Research*, 85, 325–336. <https://doi.org/10.1016/j.jbusres.2018.01.018>
- McLean, G., Osei-Frimpong, K., Al-Nabhani, K., & Marriott, H. (2020). Examining consumer attitudes towards retailers' m-commerce mobile applications – An initial adoption vs. Continuous use perspective. *Journal of Business Research*, 106, 139–157. <https://doi.org/10.1016/j.jbusres.2019.08.032>
- Michon, R., Chebat, J.-C., & Turley, L. W. (2005). Mall atmospherics: The interaction effects of the mall environment on shopping behavior. *Journal of Business Research*, 58(5), 576–583. <https://doi.org/10.1016/j.jbusres.2003.07.004>
- Millán, A., Fanjul, M. L., & Moital, M. (2016). Segmenting the Business Traveler Based on Emotions, Satisfaction, and Behavioral Intention. *Psychology & Marketing*, 33(2), 82–93. <https://doi.org/10.1002/mar.20856>
- Mondal, J., & Chakrabarti, S. (2021). The abandonment behaviour of the branded app consumer: A study using interpretive structural modelling approach. *Journal of Retailing and Consumer Services*, 63, 102695. <https://doi.org/10.1016/j.jretconser.2021.102695>
- Morosan, C., & DeFranco, A. (2016). Modeling guests' intentions to use mobile apps in hotels. *International Journal of Contemporary Hospitality Management*. <https://doi.org/10.1108/IJCHM-07-2015-0349>
- MSI. (2016). *Research Priorities 2016–2018*. Marketing Science Institute. [https://www.msi.org/uploads/articles/MSI\\_RP16-18.pdf](https://www.msi.org/uploads/articles/MSI_RP16-18.pdf)
- MSI. (2018). *Research Priorities 2018-2020*. Marketing Science Institute. [https://www.msi.org/uploads/articles/MSI\\_RP18-20.pdf](https://www.msi.org/uploads/articles/MSI_RP18-20.pdf)
- MSI. (2020). *Research Priorities 2020-2022*. Marketing Science Institute. <https://www.msi.org/wp-content/uploads/2020/09/MSI-2020-22-Research-Priorities-final.pdf>
- Mundt, K., Dawes, J., & Sharp, B. (2006). Can a brand outperform competitors on cross-category loyalty? An examination of cross-selling metrics in two financial services markets. *Journal of Consumer Marketing*, 23(7), 465–469. <https://doi.org/10.1108/07363760610713019>

- Natarajan, T., Balasubramanian, S. A., & Kasilingam, D. L. (2017). Understanding the intention to use mobile shopping applications and its influence on price sensitivity. *Journal of Retailing and Consumer Services*, 37, 8–22. <https://doi.org/10.1016/j.jretconser.2017.02.010>
- Natarajan, T., Balasubramanian, S. A., & Kasilingam, D. L. (2018). The moderating role of device type and age of users on the intention to use mobile shopping applications. *Technology in Society*, 53, 79–90. <https://doi.org/10.1016/j.techsoc.2018.01.003>
- Nylund, K. L., Asparouhov, T., & Muthén, B. O. (2007). Deciding on the Number of Classes in Latent Class Analysis and Growth Mixture Modeling: A Monte Carlo Simulation Study. *Structural Equation Modeling: A Multidisciplinary Journal*, 14(4), 535–569. <https://doi.org/10.1080/10705510701575396>
- Nylund-Gibson, K., & Choi, A. Y. (2018). Ten frequently asked questions about latent class analysis. *Translational Issues in Psychological Science*, 4(4), 440. <https://doi.org/10.1037/tps0000176>
- Oliveira-Castro, J. M. de, Ferreira, D. C. S., Foxall, G. R., & Schrezenmaier, T. C. (2005a). Dynamics of repeat buying for packaged food products. *Journal of Marketing Management*, 21(1–2), 37–61. <https://doi.org/10.1362/0267257053166730>
- Oliveira-Castro, J. M. de, Foxall, G. R., & Schrezenmaier, T. C. (2005b). Patterns of consumer response to retail price differentials. *The Service Industries Journal*, 25(3), 309–335. <https://doi.org/10.1080/02642060500050392>
- Oliveira-Castro, J. M. de, & Foxall, G. R. (2017). Consumer maximization of utilitarian and informational reinforcement: Comparing two utility measures with reference to social class. *The Behavior Analyst*, 40(2), 457–474. <https://doi.org/10.1007/s40614-017-0122-9>
- Oliveira-Castro, J. M. de, Foxall, G. R., James, V. K., Pohl, R. H. B. F., Dias, M. B., & Chang, S. W. (2008). Consumer-based brand equity and brand performance. *The Service Industries Journal*, 28(4), 445–461. <https://doi.org/10.1080/02642060801917554>
- Oliveira-Castro, J. M. de, Foxall, G. R., & Schrezenmaier, T. C. (2006). Consumer brand choice: Individual and group analyses of demand elasticity. *Journal of the Experimental Analysis of Behavior*, 85(2), 147–166. <https://doi.org/10.1901/jeab.2006.51-04>

- Oliveira-Castro, J. M. de, Foxall, G. R., Yan, J., & Wells, V. K. (2011). A behavioral-economic analysis of the essential value of brands. *Behavioural Processes*, *87*(1), 106–114. <https://doi.org/10.1016/j.beproc.2011.01.007>
- Oliveira-Castro, J. M. de, & Marques, R. S. (2017). Temporal Discounting and Marketing Variables: Effects of Product Prices and Brand Informational Reinforcement. *The Behavior Analyst*, *40*(2), 475–492. <https://doi.org/10.1007/s40614-017-0109-6>
- Oliveira-Castro, J. M., Cavalcanti, P. R., & Foxall, G. R. (2016). What consumers maximize: Brand choice as a function of utilitarian and informational reinforcement. *Managerial and Decision Economics*, *37*(4–5), 360–371. <https://doi.org/10.1002/mde.2722>
- Oliver, R. L. (1999). Whence consumer loyalty? *Journal of Marketing*, *63*(4\_suppl1), 33–44. <https://doi.org/10.1177/00222429990634s105>
- Oyedele, A., & Simpson, P. M. (2018). Streaming apps: What consumers value. *Journal of Retailing and Consumer Services*, *41*, 296–304. <https://doi.org/10.1016/j.jretconser.2017.04.006>
- Ozretic-Dosen, D., Fuduric, M., & Horvat, S. (2022). Challenging the status quo in marketing research. *Journal of Business Research*, *143*, 294–297. <https://doi.org/10.1016/j.jbusres.2022.01.077>
- Pan, W. (2001). Akaike's Information Criterion in Generalized Estimating Equations. *Biometrics*, *57*(1), 120–125. <https://doi.org/10.1111/j.0006-341X.2001.00120.x>
- Pare, V., & Dawes, J. (2012). The persistence of excess brand loyalty over multiple years. *Marketing Letters*, *23*(1), 163–175. <https://doi.org/10.1007/s11002-011-9144-3>
- Paul, J. (2019). Marketing in emerging markets: A review, theoretical synthesis and extension. *International Journal of Emerging Markets*, *15*(3), 446–468. <https://doi.org/10.1108/IJOEM-04-2017-0130>
- Pekár, S., & Brabec, M. (2018). Generalized estimating equations: A pragmatic and flexible approach to the marginal GLM modelling of correlated data in the behavioural sciences. *Ethology*, *124*(2), 86–93. <https://doi.org/10.1111/eth.12713>
- Phua, P., Kennedy, R., Trinh, G., Page, B., & Hartnett, N. (2020). Examining older consumers' loyalty towards older brands in grocery retailing. *Journal of Retailing and Consumer Services*, *52*, 101893. <https://doi.org/10.1016/j.jretconser.2019.101893>

- Porto, R. B. (2018). Consumer-based brand equity of products and services: Assessing a measurement model with competing brands. *Revista Brasileira de Marketing*, 17(2), 150–165. <https://doi.org/10.5585/remark.v17i2.3547>
- Porto, R. B. (2019). Consumer-based brand equity: Benchmarking the perceived performance of brands. *Revista Brasileira de Marketing*, 18(4), 51–74. <https://doi.org/10.5585/remark.v18i4.16383>
- Porto, R. B., & Carvalho, G. P. (2015). Dinâmica da participação de mercado durante o lançamento de novas marcas em produto de compra rotineira. *Review of Administration and Innovation - RAI*, 12(4), 205. <https://doi.org/10.11606/rai.v12i4.102027>
- Porto, R. B., & Foxall, G. R. (2019, julho 3). Marketing firm performance: When does marketing lead to financial gains? *Managerial and Decision Economics*, 42(2), 191–202. <https://doi.org/10.1002/mde.3046>
- Porto, R. B., & Lima, N. (2015). Nonlinear impact of the marketing mix on brand sales performance. *Brazilian Business Review*, 12(5), 57–77. <https://doi.org/10.15728/bbr.2015.12.5.4>
- Porto, R. B., & Melo, L. B. (2016). Intensidade de Propaganda e Precificação como Fontes Geradoras dos Conflitos entre Desempenhos de Marcas. *Revista de Administração da Unimep*, 14(1), 54–79. <https://doi.org/10.15600/1679-5350/rau.v14n1p54-79>
- Porto, R. B., & Oliveira-Castro, J. M. de. (2013a). Preditores da correspondência intenção-compra: Experimento natural com reforço das marcas. *Psicologia: Teoria e Pesquisa*, 29(1), 61–70. <https://doi.org/10.1590/S0102-37722013000100008>
- Porto, R. B., & Oliveira-Castro, J. M. de. (2013b). Say-do correspondence in brand choice: Interaction effects of past and current contingencies. *The Psychological Record*, 63(2), 345–362. <https://doi.org/10.11133/j.tpr.2013.63.2.009>
- Porto, R. B., & Oliveira-Castro, J. M. de. (2015). Consumer purchase and brand performance: The basis of brand market structure. In G. R. Foxall, *The Routledge Companion to Consumer Behavior Analysis* (1<sup>o</sup> ed, p. 175–201). Routledge.
- Porto, R. B., & Silva, A. T. V. da. (2014). Efeitos da precificação, da diferenciação e da oferta de valor no desempenho de marcas em contextos competitivos. *Revista de Administração*, 49(1), 103–115. <https://doi.org/10.5700/rausp1134>

- Porto, R. B., Watanabe, E. A. de M., Barrozo, M. M. A., & Júnior, E. X. de S. (2022). Electronic word-of-mouth advertising versus brand strength: Effects on consumers' purchasing decisions. *International Journal of Professional Business Review*, 7(1), 1–28.  
<https://doi.org/10.26668/businessreview/2022.v7i1.250>
- Qiao, Y., Cheng, Y., Yang, J., Liu, J., & Kato, N. (2017). A mobility analytical framework for big mobile data in densely populated area. *IEEE Transactions on Vehicular Technology*, 66(2), 1443–1455. <https://doi.org/10.1109/TVT.2016.2553182>
- Qiao, Y., Xing, Z., Fadlullah, Z. M., Yang, J., & Kato, N. (2018). Characterizing flow, application, and user behavior in mobile networks: A framework for mobile big data. *IEEE Wireless Communications*, 25(1), 40–49. <https://doi.org/10.1109/MWC.2018.1700186>
- Rungie, C., & Laurent, G. (2012). Brand loyalty vs. Loyalty to product attributes. In A. Diamantopoulos, W. Fritz, & L. Hildebrandt (Orgs.), *Quantitative Marketing and Marketing Management: Marketing Models and Methods in Theory and Practice* (p. 423–444). Gabler Verlag. [https://doi.org/10.1007/978-3-8349-3722-3\\_20](https://doi.org/10.1007/978-3-8349-3722-3_20)
- Rutz, O., Aravindakshan, A., & Rubel, O. (2019). Measuring and forecasting mobile game app engagement. *International Journal of Research in Marketing*, 36(2), 185–199.  
<https://doi.org/10.1016/j.ijresmar.2019.01.002>
- Ryan, J. C., & A Tipu, S. A. (2022). Business and management research: Low instances of replication studies and a lack of author independence in replications. *Research Policy*, 51(1), 104408. <https://doi.org/10.1016/j.respol.2021.104408>
- Ryle, G. (2009). *The Concept of Mind: 60th Anniversary Edition*. Routledge.  
<https://doi.org/10.4324/9780203875858>
- Saura, J. R., Palos-Sanchez, P., & Suárez, L. M. C. (2017). Understanding the Digital Marketing Environment with KPIs and Web Analytics. *Future Internet*, 9(4).  
<https://doi.org/10.3390/fi9040076>
- Scriven, J., Bound, J., & Graham, C. (2017). Making sense of common Dirichlet deviations. *Australasian Marketing Journal (AMJ)*, 25(4), 294–308.  
<https://doi.org/10.1016/j.ausmj.2017.10.007>
- Sellier, Q., Poncin, I., & Vanderdonckt, J. (2021). User, Customer and Consumer Experience: Highlighting the Heterogeneity in the Literature: *Proceedings of the 16th International Joint*

- Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, 2, 229–236. <https://doi.org/10.5220/0010316202290236>
- Seol, H. (2020). *SnowRMM : Rasch Mixture Model for jamovi* (Jamovi Module).  
<https://github.com/hyunsooseol/snowRMM>
- Shah, D., & Murthi, B. P. S. (2021). Marketing in a data-driven digital world: Implications for the role and scope of marketing. *Journal of Business Research*, 125, 772–779.  
<https://doi.org/10.1016/j.jbusres.2020.06.062>
- Shankar, V., & Balasubramanian, S. (2009). Mobile Marketing: A Synthesis and Prognosis. *Journal of Interactive Marketing*, 23(2), 118–129.  
<https://doi.org/10.1016/j.intmar.2009.02.002>
- Shankar, V., Venkatesh, A., Hofacker, C., & Naik, P. (2010). Mobile Marketing in the Retailing Environment: Current Insights and Future Research Avenues. *Journal of Interactive Marketing*, 24(2), 111–120. <https://doi.org/10.1016/j.intmar.2010.02.006>
- Sharp, B. (2014). *How brands grow: What marketers don't know* (e-Book Edition). Oxford University Press.
- Sharp, B., Wright, M., Dawes, J., Driesener, C., Meyer-Waarden, L., Stocchi, L., & Stern, P. (2012). It's a Dirichlet World: Modeling individuals' loyalties reveals how brands compete, grow, and decline. *Journal of Advertising Research*, 52(2), 203–213.  
<https://doi.org/10.2501/JAR-52-2-203-213>
- Sharp, B., Wright, M., & Goodhardt, G. J. (2002). Purchase loyalty is polarised into either repertoire or subscription patterns. *Australasian Marketing Journal (AMJ)*, 10(3), 7–20.  
[https://doi.org/10.1016/S1441-3582\(02\)70155-9](https://doi.org/10.1016/S1441-3582(02)70155-9)
- Sheth, J. (2011). Impact of Emerging Markets on Marketing: Rethinking Existing Perspectives and Practices. *Journal of Marketing*, 75(4), 166–182. <https://doi.org/10.1509/jmkg.75.4.166>
- Sims, G. (2017, fevereiro 2). *Does Android use more memory than iOS? - Gary explains*. Android Authority. <https://www.androidauthority.com/android-ios-ram-memory-usage-744848/>
- Sjostrom, T., Maria Corsi, A., Driesener, C., & Chrysochou, P. (2014). Are food brands that carry light claims different? *Journal of Brand Management*, 21(4), 325–341.  
<https://doi.org/10.1057/bm.2014.10>



- Skinner, B. F. (2003). *Ciência e comportamento humano* (11<sup>o</sup> ed). Martins Fontes.
- Son, J. (2017). The impact of initial experience and user attachment on application downloads: Information-seeking and -sharing applications. *Internet Research*, 27(2), 256–276. <https://doi.org/10.1108/IntR-03-2015-0062>
- Statista. (2020, fevereiro 28). *Smartphone users by country 2019*. Statista. <https://www.statista.com/statistics/748053/worldwide-top-countries-smartphone-users/>
- Stocchi, L., Guerini, C., & Michaelidou, N. (2017). When Are Apps Worth Paying For?: How Marketers Can Analyze The Market Performance of Mobile Apps. *Journal of Advertising Research*, 57(3), 260–271. <https://doi.org/10.2501/JAR-2017-035>
- Stocchi, L., Michaelidou, N., & Micevski, M. (2019). Drivers and outcomes of branded mobile app usage intention. *Journal of Product & Brand Management*, 28(1), 28–49. <https://doi.org/10.1108/JPBM-02-2017-1436>
- Stocchi, L., Pourazad, N., Michaelidou, N., Tanusondjaja, A., & Harrigan, P. (2021). Marketing research on Mobile apps: Past, present and future. *Journal of the Academy of Marketing Science*. <https://doi.org/10.1007/s11747-021-00815-w>
- Sultan, F., & Rohm, A. J. (2005). The Coming Era of “Brand in the Hand” Marketing. *MIT Sloan Management Review*, 47(1), 83–90.
- Tam, C., Santos, D., & Oliveira, T. (2020). Exploring the influential factors of continuance intention to use mobile Apps: Extending the expectation confirmation model. *Information Systems Frontiers*, 22(1), 243–257. <https://doi.org/10.1007/s10796-018-9864-5>
- Tang, A. K. Y. (2019). A systematic literature review and analysis on mobile apps in m-commerce: Implications for future research. *Electronic Commerce Research and Applications*, 37, 100885. <https://doi.org/10.1016/j.elerap.2019.100885>
- Tavalaei, M. M., & Cennamo, C. (2021). In search of complementarities within and across platform ecosystems: Complementors’ relative standing and performance in mobile apps ecosystems. *Long Range Planning*, 54(5), 101994. <https://doi.org/10.1016/j.lrp.2020.101994>
- The Jamovi project. (2021). *Jamovi* (1.8) [Computer software]. <https://www.jamovi.org>
- Tong, S., Luo, X., & Xu, B. (2020). Personalized mobile marketing strategies. *Journal of the Academy of Marketing Science*, 48(1), 64–78. <https://doi.org/10.1007/s11747-019-00693-3>

- Trinh, G. (2014). Predicting variation in repertoire size with the NBD model. *Australasian Marketing Journal (AMJ)*, 22(2), 111–116. <https://doi.org/10.1016/j.ausmj.2014.01.002>
- Trinh, G., Anesbury, Z. W., & Driesener, C. (2017). Has behavioural loyalty to online supermarkets declined? *Australasian Marketing Journal (AMJ)*, 25(4), 326–333. <https://doi.org/10.1016/j.ausmj.2017.10.005>
- Trinh, G., & Dawes, J. (2020). A comparison of brand loyalty between on the go and take-home consumption purchases. *Journal of Retailing and Consumer Services*, 53, 101968. <https://doi.org/10.1016/j.jretconser.2019.101968>
- Tsang, E. W. K., & Kwan, K. (1999). Replication and Theory Development in Organizational Science: A Critical Realist Perspective. *Academy of Management Review*, 24(4), 759–780. <https://doi.org/10.5465/amr.1999.2553252>
- Turley, L. W., & Milliman, R. E. (2000). Atmospheric effects on shopping behavior: A review of the experimental evidence. *Journal of Business Research*, 49(2), 193–211. [https://doi.org/10.1016/S0148-2963\(99\)00010-7](https://doi.org/10.1016/S0148-2963(99)00010-7)
- Uncles, M. D., Ehrenberg, A. S. C., & Hammond, K. (1995). Patterns of buyer behavior: Regularities, models, and extensions. *Marketing Science*, 14(3\_supplement), G71–G78. <https://doi.org/10.1287/mksc.14.3.G71>
- Uncles, M. D., Kennedy, R., Nenycz-Thiel, M., Singh, J., & Kwok, S. (2012). In 25 years, across 50 categories, user profiles for directly competing brands seldom differ: Affirming Andrew Ehrenberg's Principles. *Journal of Advertising Research*, 52(2), 252–261. <https://doi.org/10.2501/JAR-52-2-252-261>
- Uncles, M. D., & Kwok, S. (2013). Designing research with in-built differentiated replication. *Journal of Business Research*, 66(9), 1398–1405. <https://doi.org/10.1016/j.jbusres.2012.05.005>
- Uncles, M. D., & Lee, D. (2006). Brand purchasing by older consumers: An investigation using the Juster scale and the Dirichlet model. *Marketing Letters*, 17(1), 17–29. <https://doi.org/10.1007/s11002-006-3756-z>
- van de Schoot, R., Sijbrandij, M., Winter, S. D., Depaoli, S., & Vermunt, J. K. (2017). The GRoLTS-Checklist: Guidelines for Reporting on Latent Trajectory Studies. *Structural*

- Equation Modeling: A Multidisciplinary Journal*, 24(3), 451–467.  
<https://doi.org/10.1080/10705511.2016.1247646>
- Vermunt, J. K. (2010). Latent Class Modeling with Covariates: Two Improved Three-Step Approaches. *Political Analysis*, 18(4), 450–469. <https://doi.org/10.1093/pan/mpq025>
- Viglia, G., Zaefarian, G., & Ulqinaku, A. (2021). How to design good experiments in marketing: Types, examples, and methods. *Industrial Marketing Management*, 98, 193–206.  
<https://doi.org/10.1016/j.indmarman.2021.08.007>
- Vrieze, S. I. (2012). Model selection and psychological theory: A discussion of the differences between the Akaike information criterion (AIC) and the Bayesian information criterion (BIC). *Psychological Methods*, 17(2), 228–243. <https://doi.org/10.1037/a0027127>
- Wang, C., & Zheng, S. (2020). Complement or substitute? Investigating the interdependence effects among mobile social apps. *Information & Management*, 103362.  
<https://doi.org/10.1016/j.im.2020.103362>
- Wang, H., Liu, Z., Guo, Y., Chen, X., Zhang, M., Xu, G., & Hong, J. (2017). An Explorative Study of the Mobile App Ecosystem from App Developers' Perspective. *Proceedings of the 26th International Conference on World Wide Web*, 163–172.  
<https://doi.org/10.1145/3038912.3052712>
- Wang, R. J.-H. (2020). Branded mobile application adoption and customer engagement behavior. *Computers in Human Behavior*, 106, 106245. <https://doi.org/10.1016/j.chb.2020.106245>
- Wedel, M., & Kamakura, W. A. (2000). *Market Segmentation: Conceptual and Methodological Foundations* (2<sup>o</sup> ed). Springer US. <https://doi.org/10.1007/978-1-4615-4651-1>
- Wilson, D., & Winchester, M. (2019). Extending the double jeopardy and duplication of purchase laws to the wine market. *International Journal of Wine Business Research*, 31(2), 163-179.  
<https://doi.org/10.1108/IJWBR-12-2017-0072>
- Wright, M., Sharp, A., & Sharp, B. (1998). Are Australasian brands different? *Journal of Product & Brand Management*, 7(6), 465–480. <https://doi.org/10.1108/10610429810244648>
- Yang, K. C. C. (2005). Exploring factors affecting the adoption of mobile commerce in Singapore. *Telematics and Informatics*, 22(3), 257–277.  
<https://doi.org/10.1016/j.tele.2004.11.003>

- Zeger, S. L., Liang, K.-Y., & Albert, P. S. (1988). Models for Longitudinal Data: A Generalized Estimating Equation Approach. *Biometrics*, *44*(4), 1049–1060.  
<https://doi.org/10.2307/2531734>
- Zhang, J., Wu, T., & Fan, Z. (2019). Research on precision marketing model of tourism industry based on user's mobile behavior trajectory. *Mobile Information Systems*, *2019*.  
<https://doi.org/10.1155/2019/6560848>
- Zhang, L., Zhu, J., & Liu, Q. (2012). A meta-analysis of mobile commerce adoption and the moderating effect of culture. *Computers in Human Behavior*, *28*(5), 1902–1911.  
<https://doi.org/10.1016/j.chb.2012.05.008>
- Zhao, S., Ramos, J., Tao, J., Jiang, Z., Li, S., Wu, Z., Pan, G., & Dey, A. K. (2016). Discovering different kinds of smartphone users through their application usage behaviors. *2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, 498–509.  
<https://doi.org/10.1145/2971648.2971696>
- Zhu, J. J. H., Chen, H., Peng, T.-Q., Liu, X. F., & Dai, H. (2018). How to measure sessions of mobile phone use? Quantification, evaluation, and applications. *Mobile Media & Communication*, *6*(2), 215–232. <https://doi.org/10.1177/2050157917748351>

## Apêndice A – Delineamento do projeto de pesquisa: mBehavior App

Para alcançar o propósito desta tese foi idealizado como instrumento de coleta de dados um aplicativo mobile de monitoramento, tendo como principal funcionalidade o rastreamento anonimizado do comportamento do consumidor mobile em tempo real, o que possibilitaria a proposição de um painel de dados longitudinal.

Essa idealização se justificou devido à uma diversidade de barreiras à acesso de dados desse tipo até a data de sua execução, como por exemplo: i) não estar disponível painéis com esse tipo de dados para cientistas brasileiros; ii) empresas de monitoramento do mercado mobile (*e.g.*, App Annie) não realizar parcerias com a academia; e iii) a utilização de aplicativos de terceiros exigiria contato pessoal e invasivo diariamente com voluntários, o que resultaria em uma amostra por conveniência, puramente, composta por alunos.

Levando em consideração a complexidade do desenvolvimento e o rigor necessário para a validação do instrumento e as possibilidades de estudos além do escopo desta tese, eu transformei a proposta em um projeto de pesquisa mais amplo, denominado “M-Behavior: Entendendo o comportamento do consumidor mobile”. O projeto sob minha coordenação foi submetido ao comitê científico da Universidade Federal de Mato Grosso do Sul (UFMS), sendo aprovado nos conformes do Edital Propp/UFMS n. 02/2020. O mesmo conta com a colaboração de pesquisadores do Laboratório de Inovação, Gestão Estratégica e Marketing (LIGEM) da Universidade Federal de Mato Grosso do Sul (UFMS), do Grupo de Pesquisa em Marketing, Desempenho e Estratégia (Experimental) da Universidade de Brasília (UnB) e da Universidade de Sevilha. E apoio técnico de desenvolvedores do Brasil e do Japão.

Cabe acrescentar que o projeto de pesquisa M-Behavior não possui fomento (todas as despesas foram custeadas com recursos próprios da coordenadora do projeto) e, a princípio, tem duração de 36 meses (*i.e.*, até 05/2023). Considerando a duração do projeto e a proporção que tomou, a seguir serão detalhadas apenas as partes nas quais esta tese contempla.

## Proposição do instrumento de coleta de dados

O projeto mBehavior teve por propósito projetar e implementar um instrumento para coletar dados de smartphones em condições de ambiente natural (vida cotidiana). O objetivo era coletar medições quase contínuas cobrindo informações de acessos à aplicativos, informações de configurações disponíveis em um smartphone e dados declarados via questionário. Dessa forma, num primeiro momento, para o maior entendimento do que já vem sendo investigado com base em dados reais de uso de aplicativos e a obtenção de insights para a proposição do instrumento (em sua engenharia e viabilidade de cunho científico), foi realizada uma extensa revisão da literatura com os termos-chave “(mobile application) AND (adoption OR usage OR brand OR consumer)” e recorte temporal de 2010 a 2019 nas bases *Web of Science*, *Scopus* e *Emerald*.

Num segundo momento, com um esboço do instrumento em mãos, considerando a complexidade e restrição de capital humano e financeiro, optou-se pelo desenvolvimento do aplicativo (instrumento de coleta de dados) apenas para o sistema operacional Android. Essa decisão foi tomada considerando o critério de abrangência de consumidores que poderiam compor a pesquisa. E teve respaldo no painel Android vs. iOS, que apontou que 94,7% dos smartphones ativos no Brasil, até maio de 2020, possuíam sistema operacional Android (Kantar, 2020).

Com base no propósito da pesquisa, o aplicativo foi denominado de “*mBehavior App*”, acrônimo da terminologia em inglês *Mobile Behavior*. O seu desenvolvimento foi focado na captura das atividades mobile diárias de voluntários de forma discreta, em uma configuração que implementamos os princípios de privacidade por design.

A privacidade desempenhou um papel primordial na concepção e implementação do mBehavior, dada a natureza e escala dos dados compartilhados pelos participantes. A fim de satisfazer os requisitos éticos e legais para coleta dos dados e proteção da privacidade dos participantes, foi implementada uma abordagem baseada em várias medidas rigorosas. A abordagem pode ser resumida da seguinte forma:

- i) *Comunicação aos voluntários sobre privacidade* – no primeiro acesso, foi solicitado aos voluntários o cadastro de login e senha, seguidos da solicitação de leitura e aceitação do Termo de Consentimento Livre e Esclarecido (TCLE) e confirmação de ter 18 anos ou mais. Declaramos explicitamente que os dados seriam coletados para fins de pesquisa. Todos os

participantes foram informados sobre seus direitos, garantindo-lhes a plena liberdade de parar de contribuir com a pesquisa e/ou retirar seu consentimento a qualquer momento. Assim, a privacidade dos participantes foi garantida pela conformidade com a regulamentação brasileira e a participação baseada no consentimento informado, conforme exigido.

- ii) *Segurança de dados* – a segurança dos dados coletadas foi garantida por eficazes mecanismos de proteção, como criptografia, dispositivos de segurança, protocolos de acesso, arquivamento em servidores protegidos por firewall em um ambiente web seguro.
- iii) *Anonimização de dados* – nos termos da Lei nº 12.965, de 23 de abril de 2014 (Marco Civil da Internet), do Decreto nº 8.771, de 11 de maio de 2016 e da Lei nº 13.709, de 14 de agosto de 2018 (Lei Geral de Proteção de Dados Pessoais – LGPD) – que estabelecem as regras sobre a proteção de dados, notadamente, informações sobre pessoas e a circulação destes dados – o aplicativo mBehavior App coletou dados declarados e de uso em segundo plano seguindo seus parâmetros, sendo todos esses dados tratados de maneira anonimizados em consonância com a Lei LGPD.

Nos próximos subtópicos serão detalhadas as fases de validação do instrumento de coleta.

### **Validação do instrumento de coleta**

O mBehavior App começou a ser projetado em fevereiro de 2020 e seu desenvolvimento efetivo iniciou-se após a aprovação do projeto de pesquisa por comitê científico (maio de 2020). Tendo como foco o rigor científico e técnico, a validação do instrumento de coleta foi dividida em duas fases.

#### **➤ Fase I**

A Fase I de validação é composta por quatro etapas de validação, são elas:

##### *a) Validação do TCLE e Questionário inicial:*

Nessa etapa três juízes especialistas em pesquisa mercadológica avaliaram a clareza e pertinência da redação do TCLE e das perguntas do questionário inicial; do questionário também foi avaliada a relevância teórica. Todas as sugestões de melhorias foram acatadas. Em seguida, as versões ajustadas foram traduzidas para o inglês e espanhol, sendo a versão em inglês avaliada por

dois falantes de inglês e a versão em espanhol avaliada por um nativo da língua. Todos os ajustes sugeridos foram realizados.

b) *Validação técnica do aplicativo:*

No decorrer do desenvolvimento do aplicativo, a cada nova implementação foram realizadas validações técnicas/operacionais em dois smartphones, um com a versão do Android 6.0 Marshmallow e o outro com a versão Android 9.0 Pie, bem como foram realizados testes em emuladores Android com diferentes versões.

c) *Validação do aplicativo e do site por juízes:*

Nessa etapa foram contactados oito juízes/pesquisadores que aceitaram realizar a validação, dentre eles quatro eram da área de marketing, dois da área de estratégias, um da área de engenharia de produção e um da área de engenharia de software. Essa diversificação foi visada para uma avaliação mais rigorosa de diferentes perspectivas referente à adequação do instrumento e clareza na comunicação.

Após a aceitação de participação, foi solicitado aos juízes o e-mail que cada um tinha cadastrado na loja de aplicativos Google Play Store para que eles pudessem ter acesso a versão beta do aplicativo e realizar a simulação de uso do aplicativo como os consumidores veriam. Em seguida, foi enviado por e-mail o instrumento de validação, que era composto por: (i) uma breve descrição do propósito da pesquisa e do aplicativo; (ii) os passos-a-passos da realização da avaliação; (iii) instruções de qual versão do app (português, inglês ou espanhol) foi designada para avaliar e o tempo de permanência com o app instalado (o mínimo instruído foi três dias); e (iv) o Formulário de Validação que foi dividido em três partes – 1) validação do questionário inicial e TCLE (versão final no app), 2) validação do layout e funcionamento do mBehavior App, e 3) validação da descrição do mBehavior App no Google Play Store e do conteúdo do site mBehavior (desenvolvido, além do app, com o propósito de ampliar a transparência e comunicação com os voluntários).

Dos juízes, 75% retornaram o Formulário de Validação no prazo combinado. Os apontamentos, sugestões e relatos foram enriquecedores para a consolidação do instrumento de coleta de dados e, principalmente, fundamentais para o aprimoramento operacional do app, uma vez que, conforme é de conhecimento de profissionais da área e engenheiros de *software*, cada versão de Android, modelo de smartphone e configuração definida como padrão no dispositivo



pode influenciar/afetar tanto na apresentação gráfica quanto nas restrições de funcionamento dos aplicativos, sendo esse um dos motivos pelo qual os apps passam por constantes atualizações.

d) *Validação internacional do mBehavior App pelo Google Play Console:*

Posteriormente à realização das três etapas anteriores, em 10 de junho de 2020, o mBehavior App passou da versão beta para 1.0.0. Foi solicitada a aprovação da publicação do app em três idiomas (português, inglês e espanhol) na Google Play Store em 39 países. Isso permitiu uma validação internacional do instrumento com um maior rigor, em especial, referente às adequações exigidas pela LGPD. Cabe relatar que a equipe da Google Play solicitou alguns ajustes para a adequação internacional do app e, após o seu cumprimento, o mBehavior App foi aprovado. Em 21 de junho de 2020, a versão 1.0.9 foi publicada na plataforma em todos os 39 países solicitados.

➤ **Fase II**

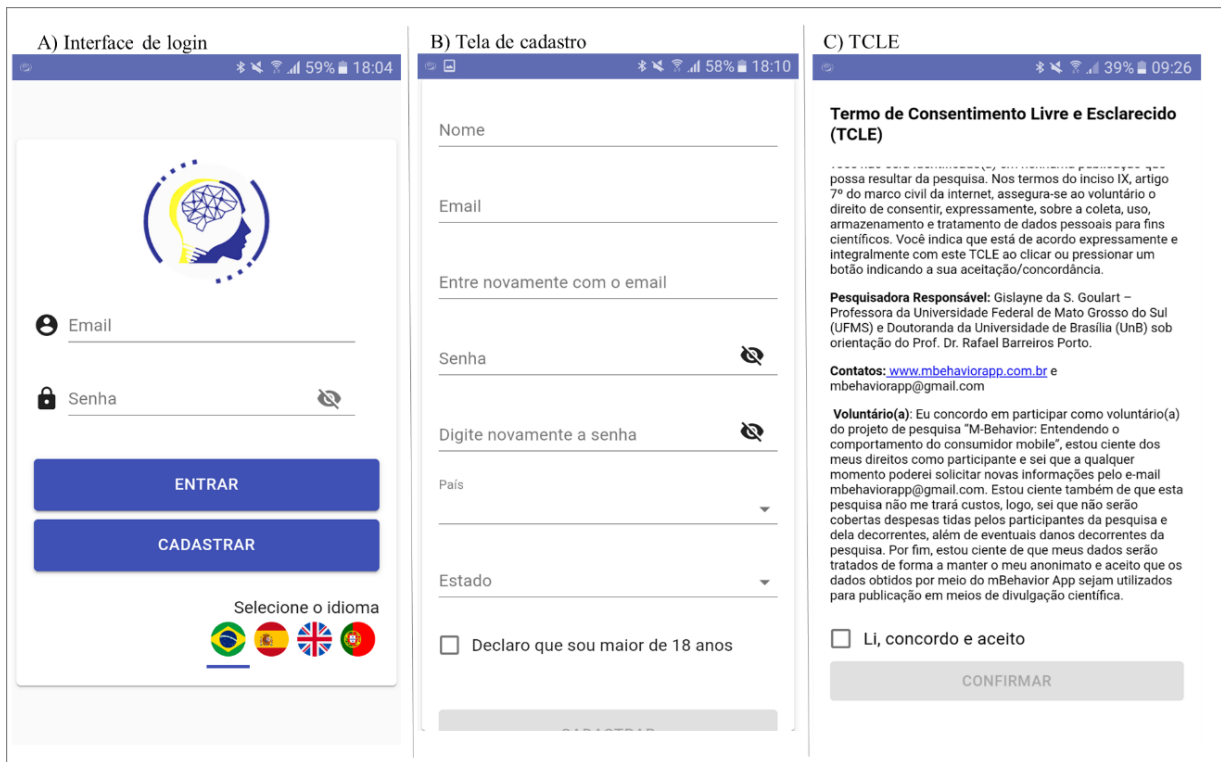
A Fase II de validação do instrumento de coleta foi realizada com o propósito de aprimorar e ajustar o banco de dados, APIs implementadas, sistema e melhorias no app devido às diferentes versões de sistemas operacionais que foram integrando a pesquisa. Essa fase ocorreu entre 25 de junho a 20 de julho de 2020, que corresponde ao período inicial de divulgação e coleta de dados.

### **Apresentação da interface do mBehavior App**

O mBehavior apresenta uma interface clean, projetada para facilitar a interação. Na Figura 11 são apresentadas as telas das interações iniciais do usuário com o app. Na imagem A é apresentada a tela de login, nela o usuário poderia escolher o idioma em que iria usar o app e fazer o login quando opta-se por participar da pesquisa. Ao clicar em “cadastrar” o usuário era direcionado para tela de cadastramento de login e confirmação de ter mais de 18 anos (imagem B, Figura 11). Logo após, o voluntário era direcionado para ler e aceitar o TCLE. Cabe acrescentar que o botão de confirmação somente era ativado se a página do TCLE fosse rolada até o fim e fosse assinalada a caixinha de consentimento (imagem C, Figura 12). Por fim, nesse primeiro acesso, o voluntário era direcionado para responder um questionário inicial.

**Figura 12**

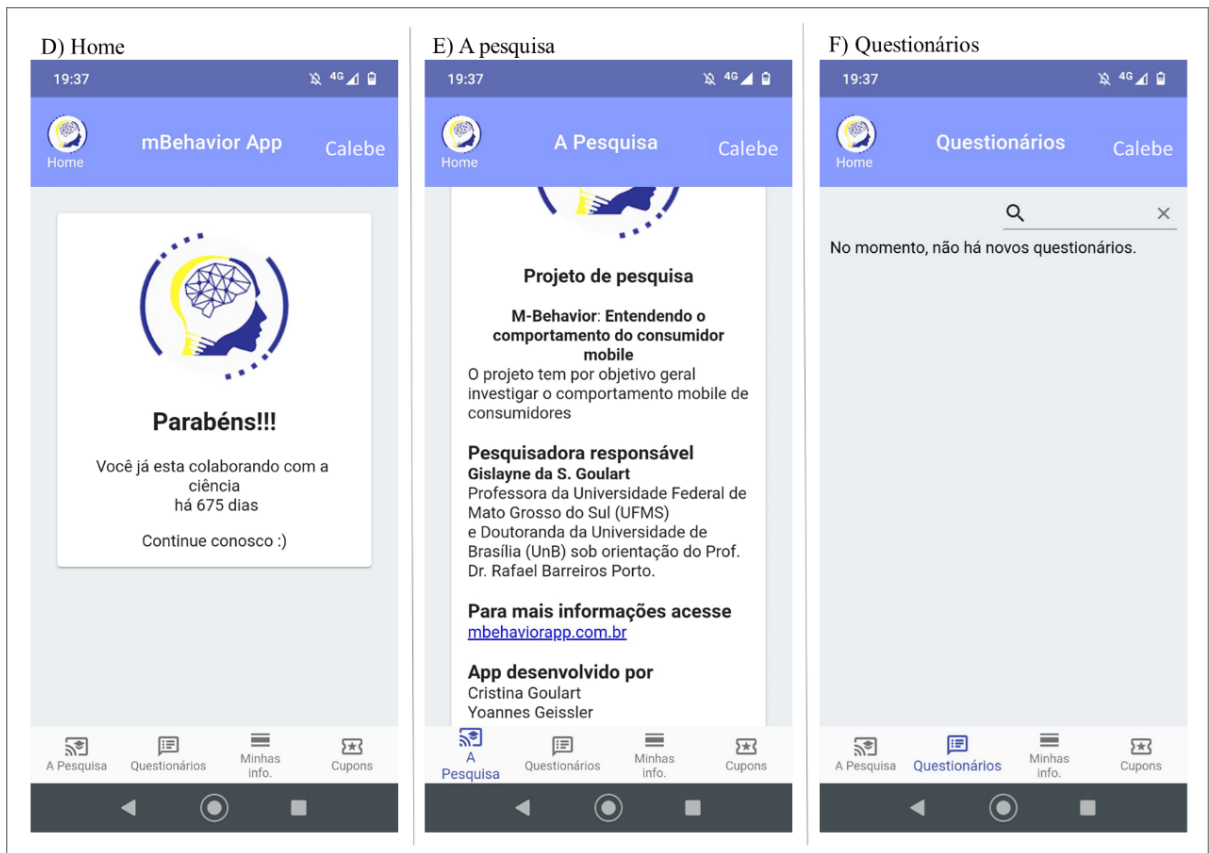
Apresentação da interface de interação inicial do mBehavior App



Na tela “Home” (imagem D, Figura 13) é expressa a nossa felicitação ao voluntário, seguida do quantitativo de dias que ele permanece com o app logado. Ao clicar em “A Pesquisa” (imagem E, Figura 13), o voluntário podia consultar informações referentes ao projeto e acessar o canal de *feedback* por meio do qual o participante poderia entrar em contato com os responsáveis pela pesquisa a qualquer momento, bem como foi disponibilizado o link da página *Web* <http://mbehaviorapp.com.br/> (<https://linktr.ee/mBehaviorApp>) em que consta informações gerais sobre a pesquisa, tais como: breve descrição do projeto mBehavior; onde estamos (*i.e.*, países em que há/houve voluntários); as políticas de privacidades; detalhes dos dados coletados; respostas às perguntas mais frequentes sobre a pesquisa; e informações sobre os envolvidos diretamente com o projeto. No menu do app foi inclusa a aba “Questionário” (imagem F, Figura 13), essa funcionalidade permitia que os pesquisadores enviassem questionários aos participantes, seja para complementar a investigação sobre o comportamento mobile seja sobre outras temáticas.

**Figura 13**

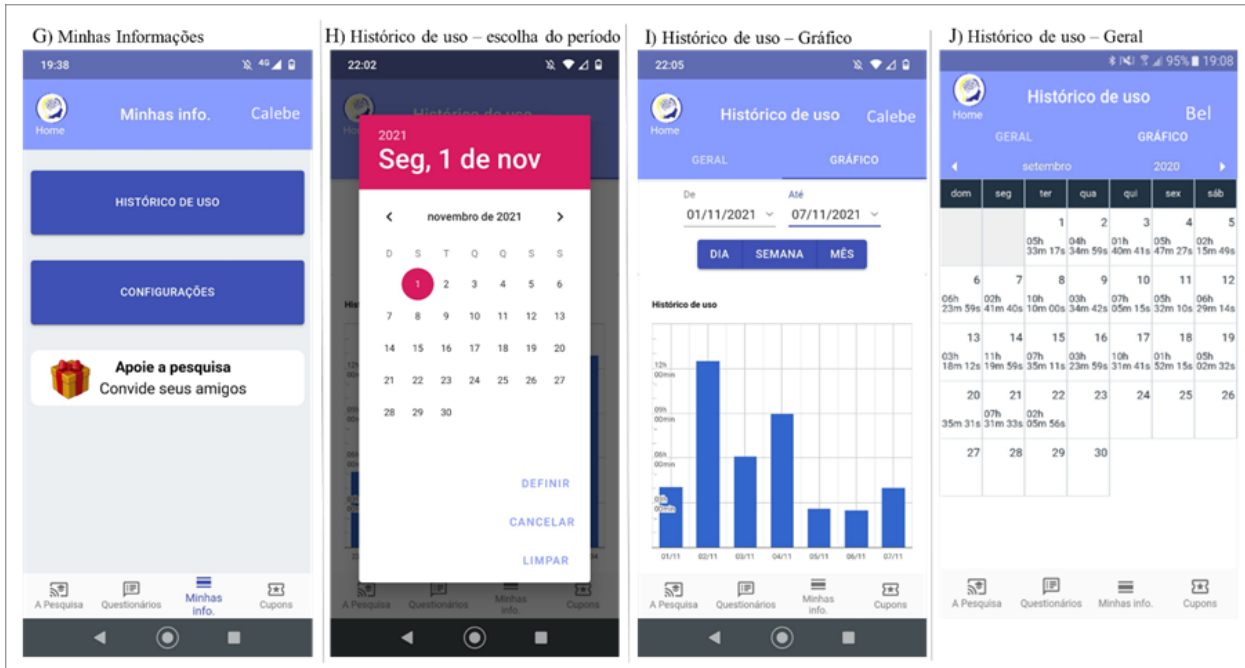
*Apresentação do menu do mBehavior App - parte 1*



Na aba “Minhas informações” (imagem G, Figura 14) foram disponibilizados três grupos de recursos – histórico de uso, configurações e apoio a pesquisa. Esse último, consistia em um recurso para o usuário convidar outras pessoas a participarem da pesquisa. Ao clicar no botão “Apoie a pesquisa”, o mBehavior App criava um convite personalizado com o nome do usuário e link para compartilhar com outrem por meio de aplicativos de comunicação (*e.g.*, WhatsApp).

**Figura 14**

*Apresentação do menu do mBehavior App - parte 2*



Como forma dos voluntários de recompensar os voluntários pela contribuição com a pesquisa, foi implementado o recurso de gerenciador de tempo de uso do smartphone para os usuários que desejassem acompanhá-lo ao longo do tempo. Ao clicar no botão “Histórico de Uso”, o usuário poderia escolher o período que gostaria de consultar o seu tempo de uso (imagem H, Figura.14) e, em seguida, compará-lo em um gráfico em intervalo semanal ou mensal, bem como consultar um dia em específico (imagem I, Figura 14). Por padrão, o mBehavior App apresentava, também, o tempo de uso em calendário do mês corrente, mas o usuário também poderia consultar outros meses (imagem J, Figura 14).

Ainda, o usuário podia acompanhar, a qualquer momento, o tempo de uso no dia corrente em uma notificação fixada na aba de notificações gerais do smartphone (imagem K, Figura 15).

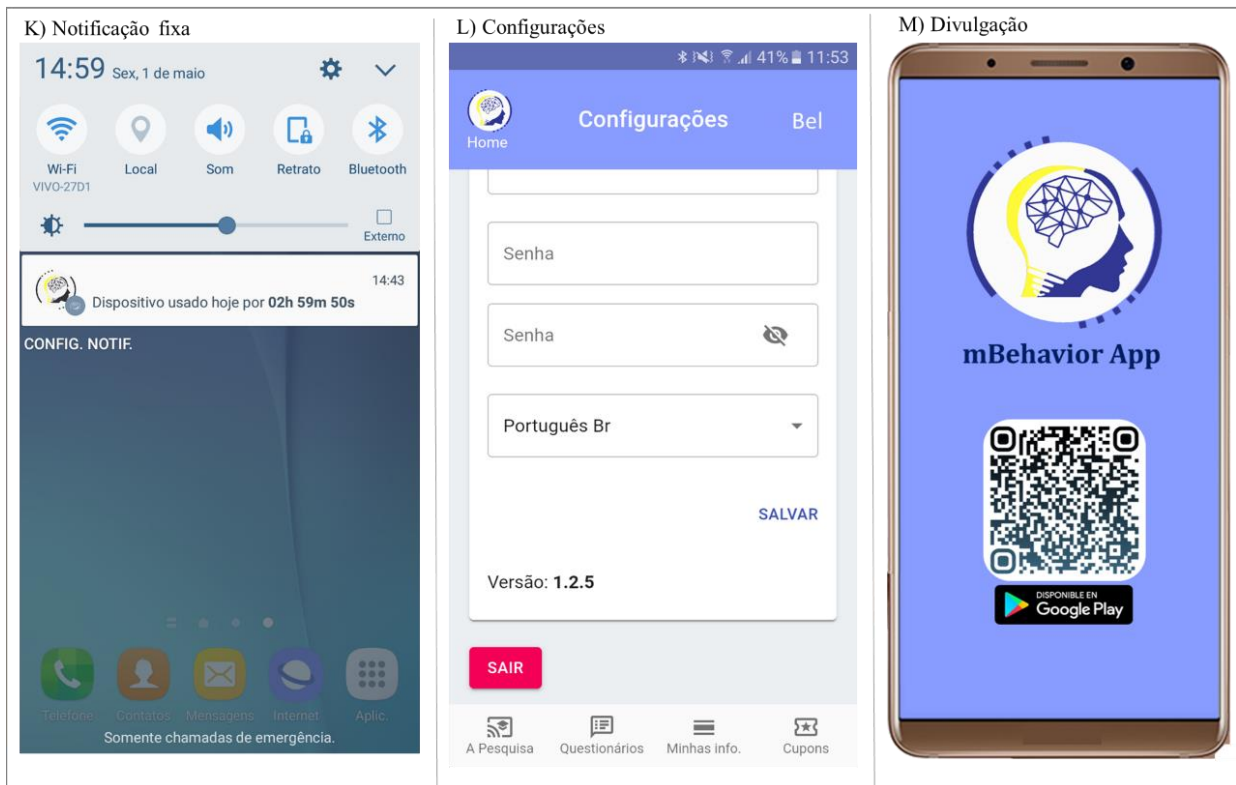
Essa notificação fixada foi fundamental para a coleta de dados do monitoramento em segundo plano, uma vez que, por padrão, a configuração do sistema operacional Android pode finalizar aplicativos que não estejam ativos, seja para economia de bateria seja por outros motivos de otimização do funcionamento. Cabe acrescentar que procuramos desenvolver o mBehavior App para realizar o monitoramento em segundo plano de modo que consumisse o mínimo possível de

bateria, bem como implementamos a regra de comunicação do app com o servidor em tempo real somente quando smartphone do voluntário estivesse conectado em uma rede Wifi, caso contrário os dados de log coletados seriam armazenados localmente e somente transferidos para o servidor por rede móvel às 23h (local do dispositivo), evitando, assim, o máximo possível de consumo de dados móvel do usuário.

Por fim, no menu Minhas Informações, na aba “Configurações” (imagem L, Figura 15) estava disponível ao usuário: i) a possibilidade de alterar nome, senha e idioma do app; ii) verificar a versão do app que estava utilizando; e iii) sair do app – ao clicar em sair, era encerrada a comunicação com o servidor e nenhuma informação mais era coletada, mesmo que o voluntário permanecesse com o mBehavior App instalado e usufruísse do recurso de tempo de uso apresentado na aba de notificações gerais do smartphone.

**Figura 15**

*Apresentação do menu do mBehavior App - parte 3*



## **Coleta de dados**

O público-alvo da pesquisa (para esta tese) foi a população brasileira acima de 18 anos que possuía smartphone com sistema operacional Android e acesso à internet. O recrutamento de voluntários ocorreu por diferentes meios de comunicação (*e.g.* mídias sociais, e-mail e sites). A participação dos voluntários consistiria em responder algumas perguntas e permanecer com o mBehavior App instalado em seu smartphone por 90 dias ou pelo período que desejasse colaborar com a ciência no Brasil.

Como já mencionado, o mBehavior App foi projetado para ser minimamente invasivo, focando na coleta de dados anonimizados referentes ao comportamento de uso de mobile apps. Desse modo:

- O simples fato de um indivíduo instalar o mBehavior App em seu smartphone não significou que ele estava colaborando com a pesquisa, nem que algum dado foi coletado;
- A coleta de dados somente ocorreu após o voluntário criar o seu login e senha, confirmar ter 18 anos ou mais e ler e aceitar o TCLE;
- O nível de detalhamento dos dados coletados variou de acordo com as permissões aceitas e a versão do app instalada no dispositivo (podendo variar da versão 1.0.9 a 1.3.4);
- Em ocasiões que o usuário optou, seja por meio de gerenciadores de cachê seja bateria e/ou remoção do login, interromper a comunicação com o mBehavior App nenhum dado foi transferido para os servidores.

Portanto, salienta-se que quando mencionado dias de registros se referem aos dias de uso efetivo (sequenciado ou não) que os dispositivos se comunicaram com os servidores do mBehavior App. No próximo subtópico será detalhado o processamento e tratamento dos dados.

## **Processamento e Tratamento dos Dados**

Todos os dados coletados por meio do mBehavior App são armazenados em formato não estruturado em servidores protegidos por firewall em um ambiente web seguro. Devido à alta priorização da privacidade, a preservação do direito de interromper a transferência de dados a qualquer momento e o controle do nível de fornecimentos dos dados pelos voluntários foram

necessárias proposições de modelagem analítica dos dados; e tratativas para a conversão de dados em medidas mercadológicas comparáveis e interpretáveis para a realização de estudos.

### **Delimitação do recorte amostral para esta tese**

Dado o propósito da tese de uma investigação longitudinal, considerando um período de quatro semanas e os prazos para a sua finalização, foi realizado um recorte amostral dos dados de 23 de julho a 14 de novembro de 2020. Foram selecionados os indivíduos (`user_id`) que atendiam os critérios de inclusão conforme o objetivo de cada estudo que compõem a tese.

Em uma análise descritiva prévia, considerando esse recorte temporal, constatou-se um N amostral de 717 voluntários que instalaram o mBehavior App e preencheram o questionário inicial, dos quais 79,22% declararam residir na região Centro-Oeste do Brasil. Neste contexto, optou-se por consultar três doutores pesquisadores de marketing referente ao melhor recorte amostral para a tese com base nessa análise prévia. Por unanimidade a recomendação foi delimitar a amostra apenas para a região Centro-Oeste do Brasil, uma vez que os resultados tenderiam a ser mais coesos, do que se fosse integrado os dados de voluntários das regiões Nordeste, Sudeste e Sul do Brasil. Dessa forma, foi criada a ‘User-Whitelist’ – uma lista apenas com `user_id` da região Centro-Oeste que atendiam o escopo favorável para realização dos estudos da tese.

Com base na User-Whitelist, foram selecionados apenas os `user_id` com colaboração superior a um dia, resultando em uma amostra de 525 consumidores/voluntários. Em um segundo momento, constatou-se que alguns `user_id` apresentavam registros para mais de um dispositivo (`phone_id`) e que alguns modelos de dispositivos não permitiram coletar dados sobre se uma sessão de um aplicativo ocorreu em tela ligada ou não (`phone_time_screen`).

Tais aspectos resultaram, assim, na necessidade da criação de dois parâmetros de lista: i) ‘Phone-Whitelist0’ – uma lista apenas com os `phone_id` que tiveram uma comunicação mais contínua e menos restrita com os servidores do mBehavior App; e ii) ‘Phone-Whitelist1’ – uma lista apenas com os `phone_id` que compunham a ‘Phone-Whitelist0’, que apresentavam dados de time screen (fundamental para o tratamento de dados com recorte longitudinal, detalhado posteriormente). No próximo subtópico será detalhado como foi a mineração e tratamento dos dados de acessos aos aplicativos.

## **Detalhamento do tratamento de dados longitudinais – acessos aos aplicativos**

### **➤ Criação do detalhamento de acessos ao aplicativo:**

1. Consultas de interações conforme tabela `phone_usage` de acordo com o campo `'started_at'`, seguindo a data e hora conforme registrado no banco de dados;
  - 1.1 Obs. A adequação da data e hora registrado no banco, para o fuso horário do usuário, é realizada no script de sumarização (etapa 10);
2. Aplicação de limitadores de escopo na consulta:
  - 2.1. User Whitelist: usuários que atendem a um escopo de uso que favorece uma quantidade mínima de registros para estudo;
  - 2.2. Phone Whitelist: dispositivos móveis que atendem a um melhor escopo de utilização;
  - 2.3. App Blacklist: apps de sistema ou altamente subutilizados [apps que rodam mais em backend];
3. [Opcional, realizado por padrão] Remoção de interações realizadas com a tela desligada: são consultadas as sessões de tela ligada em `phone_time_screen` e são removidas as interações que ocorrem parcial ou completamente fora de sessões de tela ligada;
4. [Opcional, mas realizado por padrão] Remoção de interações 'instantâneas' ou errôneas: removidos os registros onde a data e hora de término é menor ou igual à data e hora de início;
5. [Opcional, mas realizado por padrão] Sumarização de interações 'duplicadas': para interações do mesmo usuário, telefone e app, com a mesma data e hora de início, é mantida a maior data e hora de término;
6. Criação de 'pai' para cada interação: considerando a chave de usuário, telefone e app (`phone_app_id`) e data e hora de término do pai, contra usuário, telefone e app (`phone_app_id`) e data e hora de início do filho; são realizados N passos (parametrizável, padrão 4), permitindo uma tolerância de 0 a N-1 segundos entre o término da interação pai e a interação filho; para os casos em que uma interação encontre mais de um pai, sempre é considerado o 'maior' pai, que seja 'menor' que o filho (id de registro no banco deve ser menor que o filho, dentre os ids menores, o maior é considerado);



7. Sumarização dos acessos: a partir do registro de pai criado na etapa anterior, os acessos são criados com base na data e hora de início do pai, data e hora de término do 'menor' filho e contagem total de interações;

8. [Opcional, mas realizado por padrão] Achatamento dos acessos: após as etapas anteriores, ainda ocorrem incidências de acessos simultâneos, podendo muitos serem ocasionados por interações em segundo plano em decorrência de ações do usuário, todos os acessos que, em algum momento se sobrepõem, são novamente sumarizados, mantendo a menor data e hora de início do pai, maior data e hora de término e contagem total de interações;

9. Criação de indicador de switch: são criados novamente 'pai' para cada acesso, dessa vez considerando usuário, telefone e data e hora de término do pai, contra usuário, telefone e data e hora de início do filho;

➤ **Sumarização geral dos acessos:**

10. A partir dos arquivos particionados gerados na etapa anterior, todos são carregados e têm suas datas e horas ajustadas de acordo com o fuso horário de cada usuário;

11. Os registros de acessos são então sumarizados por data, usuário, telefone e app;

12. São criados, para cada data e usuário, as regras de intervalo (30 dias, 15 dias // registros empilhados), nas quais são observados para cada usuário se em um dado dia, existem N ou mais acessos (parametrizável, padrão 2) em apps da categoria de comunicação; as datas de cada usuário que atenderem às regras aplicadas são delimitadas em um intervalo sequencial;

➤ **Análise dos acessos:**

13. Para cada categoria, cada tipo de intervalo (30 dias, 15 dias), cada intervalo T disponível, são sumarizados os acessos a nível de app, criando a quantidade total de acessos, usuários distintos, uso da marca para cada app e intervalo.

## Apêndice B – Modelo de NBD-Dirichlet aplicado ao uso de marcas de aplicativos

O modelo estocástico NBD-Dirichlet proposto por Ehrenberg e colegas (cf. Ehrenberg & Goodhardt, 1970; Ehrenberg et al., 2004; Goodhardt et al., 1984) é um dos chamados modelos de ordem zero, que usam distribuições de probabilidade paramétricas para modelar o comportamento do comprador “como se fosse aleatório”. Ehrenberg e colegas (cf. Ehrenberg et al., 2004; Goodhardt et al., 1984) reconhecem que o comportamento de compra do consumidor pode ser impulsionado por motivações intrínsecas e situacionais (e.g., promoções, falta de estoque de uma marca ou uma visita da sogra), e embora possa não ser verdadeiramente aleatório no nível individual, quando analisado no nível agregado da marca, pode ser descrito probabilisticamente.

O modelo originalmente combina duas funções de densidade de probabilidade: a Distribuição Binomial Negativa (NBD - *Negative Binomial Distribution*), para incidência de compra da categoria, e a Distribuição Multinomial Dirichlet (DMD - *Dirichlet Multinomial Distribution*), para escolha da marca, para modelar simultaneamente o número de compras para cada marca concorrente em uma categoria em um período fixo (Ehrenberg et al., 2004; Goodhardt et al., 1984). Na presente pesquisa foi realizada uma adaptação das métricas para o contexto de uso efetivo de marcas de aplicativos, assim o modelo de Dirichlet será uma combinação da NBD da taxa de uso da categoria e da DMD dos usos das marcas de apps individuais, condicionada à taxa de uso de apps da categoria. A função densidade de probabilidade de NBD é

$$f(n) = (1 + a)^{-k} \frac{\Gamma(n+k)}{n!\Gamma(k)} \left(\frac{a}{1+a}\right)^n \quad (1)$$

onde  $n$  é a taxa de uso da categoria,  $k$  e  $a$  são os parâmetros de forma e escala de distribuição gama, respectivamente.

E a função densidade de probabilidade de DMD é

$$f_{\alpha_1, \alpha_2, \dots, \alpha_m}(x_1, x_2, \dots, x_m | x_1 + x_2 + \dots + x_m = n) = \frac{\Gamma(s)n!}{\Gamma(s+n)} \prod_{j=1}^m \frac{\Gamma(\alpha_j + x_j)}{x_j! \Gamma(\alpha_j)} \quad (2)$$

onde  $m$  é o número de marcas de apps;  $x_j$  são as taxas de uso de marcas de apps,  $j = 1, \dots, m$ ;  $\alpha_j$  são parâmetros de heterogeneidade de escolha da marca de DMD; e  $S$  é a soma de  $\alpha_j$ , um parâmetro de comutação da categoria.

As duas principais distribuições (NBD e DMD) são consideradas independentes. Deste modo, a propensão ao uso da categoria é independente da preferência por marcas específicas,

condicionada à escolha da categoria. Com base nas fórmulas (1) e (2), a função de densidade de probabilidade NBD-DMD é

$$f_{\alpha_1, \alpha_2, \dots, \alpha_m}(x_1, x_2, \dots, x_m) = (1 + a)^{-k} \frac{\Gamma(n+k)}{n! \Gamma(k)} \left( \frac{a}{1+a} \right)^n \frac{\Gamma(s)n!}{\Gamma(s+n)} \prod_{j=1}^m \frac{\Gamma(\alpha_j + x_j)}{x_j! \Gamma(\alpha_j)} \quad (3)$$

Para estimar o modelo foi utilizado o software Dirichlet (Kearns, 2010).

### Apêndice C – Duplicação para marcas de aplicativo por categoria

**Tabela 6**

*Duplicação para marcas de aplicativo da categoria Comunicação*

Consumidor de . . .	Penetração (%)	% que também usa (SPI)					
		WhatsApp	Google Chrome	Gmail	Todas as outras marcas (41)	Messenger	WhatsApp Business
WhatsApp Messenger	97,6		97,6 (1,0)	91,9 (1,0)	87,8 (1,0)	74,8 (1,0)	7,3 (0,9)
Google Chrome	96,8	98,4 (1,0)		91,8 (1,0)	88,5 (1,0)	73,8 (1,0)	8,2 (1,0)
Gmail	92,1	97,4 (1,0)	96,6 (1,0)		87,9 (1,0)	75 (1,0)	8,6 (1,1)
Todas as outras marcas (41)	88,1	97,3 (1,0)	97,3 (1,0)	91,9 (1,0)		75,7 (1,0)	7,2 (0,9)
Messenger	74,6	97,9 (1,0)	95,7 (1,0)	92,6 (1,0)	89,4 (1,0)		8,5 (1,1)
WhatsApp Business	7,9	90 (0,9)	100 (1,0)	100 (1,1)	80 (0,9)	80 (1,1)	
<i>Duplicação média</i>	76,2	96,2	97,4	93,6	86,7	75,8	8,0
<i>Duplicação média esperada</i>		97,8	97,0	92,2	88,2	74,7	7,9
Correlação (observada x esperada) 0,99 (p=0,000)							

*Nota.* Período de análise = um mês; (SPI) = Índice de compartilhamento de partição

**Tabela 7***Duplicação para marcas de aplicativo da categoria de Educação*

Consumidor de . . .	Penetração (%)	% que também usa (SPI)						
		Todas as outras marcas (76)	Sou UFMS	Moodle	Google Classroom	Duolingo	Passei Direto	12min - Resumos de Livros
Todas as outras marcas (76)	34,9		31,8 (1,0)	29,5 (1,1)	31,8 (1,2)	13,6 (1,7)	6,8 (1,0)	4,5 (0,8)
Sou UFMS	23,0	48,3 (1,0)		41,4 (1,5)	31 (1,2)	6,9 (0,9)	13,8 (2,0)	3,4 (0,6)
Moodle	19,8	52 (1,1)	48 (1,5)		24 (0,9)	4 (0,5)	4 (0,6)	4 (0,7)
Google Classroom	19,0	58,3 (1,2)	37,5 (1,2)	25 (0,9)		8,3 (1,1)	4 (0,6)	4,2 (0,7)
Duolingo	5,6	85,7 (1,7)	28,6 (0,9)	14,3 (0,5)	29 (1,1)		0	0
Passei Direto	4,8	50 (1,0)	66,7 (2,0)	16,7 (0,6)	17 (0,6)	0		0
12min - Resumos de Livros	4,0	40 (0,8)	20 (0,6)	20 (0,7)	20 (0,7)	0	0	
<i>Duplicação média</i>	15,9	55,7	38,8	24,5	25,3	5,5	4,8	2,7
<i>Duplicação média esperada</i>		49,4	32,6	28,1	27,0	7,9	6,7	5,6

Correlação (observada x esperada) 0,99 (p=0,000)

*Nota.* Período de análise = um mês; (SPI) = Índice de compartilhamento de partição; Desvios gerenciais significativos são destacados em cinza claro (<0,8) e cinza escuro (> 1,2)

Tabela 8

Duplicação para marcas de aplicativo da categoria Saúde & Fitness

Consumidor de ...	Penetração (%)	% que também usa (SPI)										
		Todas as outras marcas (51)	Samsung Health	Strava	Calendário Menstrual, Período Fértil e Ovulação	Meu Calendário Menstrual Flo.	Guardiões da Saúde	Mi Fit	Adidas Running by Runtastic	Bodytech	Nike Training Club	Queima Diária
Todas as outras marcas (51)	28,6		13,9 (0,8)	8,3 (0,6)	11,1 (0,9)	5,6 (0,5)	11,1 (1,1)	5,6 (1,1)	2,8 (1,1)	5,6 (2,2)	5,6 (2,2)	2,8 (1,1)
Samsung Health	10,3	38,5 (0,8)		0	7,7 (0,6)	0	0	0	0	15,4 (6,0)	15,4 (6,0)	0
Strava	8,7	27,3 (0,6)	0		9,1 (0,7)	0	9,1 (0,9)	9,1 (1,8)	0	0	0	0
Calendário Menstrual, Período Fértil e Ovulação	7,9	40 (0,9)	10 (0,6)	10 (0,7)		0	10 (1,0)	10 (2,0)	0	0	0	0
Meu Calendário Menstrual Flo.	7,1	22,2 (0,5)	0	0	0		22,2 (2,2)	0	0	0	0	0
Guardiões da Saúde	6,3	50 (1,1)	0	12,5 (0,9)	12,5 (1,0)	25 (2,2)		12,5 (2,4)	0	0	0	0
Mi Fit	3,2	50 (1,1)	0	25 (1,8)	25 (2,0)	0	25 (2,4)		0	0	0	0
Adidas Running by Runtastic	1,6	50 (1,1)	0	0	0	0	0	0	0	0	0	0
Bodytech	1,6	100 (2,2)	100 (6,0)	0	0	0	0	0	0		100 (39,1)	0
Nike Training Club	1,6	100 (2,2)	101 (6,0)	0	0	0	0	0	0	100 (39,1)		0
Queima Diária	1,6	50 (1,1)	0	0	0	0	0	0	0	0	0	0
<i>Duplicação média</i>	7,1	52,8	22,4	5,6	6,5	3,1	7,7	3,7	0,3	12	12	0,3
<i>Duplicação média esperada</i>		46,0	16,6	14,1	12,8	11,5	10,2	5,1	2,6	2,6	2,6	2,6

Correlação (observada x esperada) 0,90 (p=0,000)

Nota. Período de análise = um mês; (SPI) = Índice de compartilhamento de partição; Desvios gerenciais significativos são destacados em cinza claro (<0,8) e cinza escuro (> 1,2)

## **Apêndice D – Indicador de força da marca: Proposição da medida para marcas de aplicativos**

### **Contextualização**

O Indicador de força da marca, proposto por Oliveira-Castro et al. (2008), é formado pelas métricas de familiaridade (conhecimento) e qualidade percebida das marcas (MCQ). A qualidade percebida da marca consiste no julgamento do consumidor da qualidade geral do bem ou da superioridade do bem em relação ao seu propósito pretendido (Aaker, 1996; Keller & Brexendorf, 2019), sendo frequentemente baseado em seus atributos e/ou experiência de uso anterior (Oliveira-Castro et al., 2008; Porto, 2018). E, segundo Keller e Brexendorf (2019), é uma das percepções mais importantes que os consumidores podem ter em relação a uma marca, pois reflete, em geral, as percepções de valor e satisfação.

No âmbito virtual, os consumidores são estimulados constantemente a avaliar bens e marcas por meio de mecanismos de classificação por estrelas contidos em plataformas digitais. Estudiosos têm interpretado essa classificação como o grau de satisfação dos consumidores em relação a um bem/marca que reflete a qualidade percebida do bem pelo consumidor (Biviji et al., 2020; Li et al., 2020; Zhu & Zhang, 2010).

Lojas de aplicativos também adotam esse tipo de classificação, onde os usuários podem avaliar um aplicativo em uma escala de um (pontuação mais negativa) a cinco (pontuação mais positiva). A Google Play, por exemplo, apresenta aos consumidores a nota média dos aplicativos em destaque sempre que um app é visualizado na loja. Já para os gestores dos aplicativos a nota média é apresentada no painel do Google Play Console como uma métrica de qualidade percebida, que pode ser monitorada diariamente e em comparação com a média geral dos concorrentes (Google, 2020). Com base no exposto, propõe-se que a classificação por estrelas é uma medida plausível para mensurar a qualidade percebida das marcas de aplicativos pelo consumidor, considerando o seu cenário competitivo.

A familiaridade com a marca (conhecimento da marca), em um aspecto amplo, é a fonte dos efeitos diferenciais de uma marca, como qualquer tipo de associação mental do consumidor que o leva reconhecer/lembrar da marca e da categoria de bem a que pertence (Keller & Brexendorf,

2019), sendo estimulada, inicialmente, pelas próprias atividades de marketing da marca (*e.g.*, publicidade e branding) e, posteriormente, podendo ser propagada pelo ambiente social (*e.g.*, familiares, amigos e comunidades digitais), levando-a a se tornar mais familiar e importante ao consumidor (Keller & Brexendorf, 2019; Porto, 2018). No âmbito virtual, a possibilidade de os consumidores terem contato em algum momento com marcas diversas de diferentes lugares são amplas e os proporciona saber o quanto uma marca tem sido considerada por grupos, por exemplo, ao observar quantas pessoas já adquiriram a marca X em um e-commerce ou já a avaliaram (Finkelstein et al., 2017; Keller, 2022).

No mercado de apps, o download do app representa uma intenção de uso, mas não necessariamente o grau de envolvimento/interação do usuário com o app. Já a avaliação por estrelas tende a revelar que o usuário interagiu/usou pelo menos uma vez o app, o que revela que quanto mais avaliações um app possui mais pessoas já o utilizaram em algum momento. Assim, ambos têm sido considerados por especialistas como medidas que refletem o quão conhecido/popular é um app (Biviji et al., 2020; Finkelstein et al., 2017; Zhu & Zhang, 2010). Dessa forma, propõe-se que o quantitativo de downloads e de avaliações, em conjunto, podem ser utilizados como uma métrica proximal mais robusta de conhecimento da marca de apps.

Cabe acrescentar que o Google Play Store permite que mesmo apps com um quantitativo pequeno de avaliações já seja apresentada na página do app a sua nota média (Google, 2020). Dessa forma, a qualidade percebida de uma marca de app seria independente diretamente da quantidade de avaliações, demonstrando-se, assim, viável considerá-la separadamente, de modo que, mesmo apps poucos conhecidos, podem aparecer entre apps com *scores* altos de qualidade.

Em linhas gerais, a escolha desses fatores também se justifica com base no estudo de Porto (2018) que sugere que, ao mensurar as métricas de familiaridade e qualidade percebida da marca, é relevante a consideração de percepções de consumidores que tiveram algum contato com a marca (experiência).

Assim, sob a ótica do marketing, essas medidas poderiam ser interpretadas como possíveis medidas de força da marca, uma vez que são geradas pelos consumidores e têm demonstrado influenciar outros consumidores. Portanto, poderiam ser consideradas como medidas de mensuração de reforço social programado da marca (reforço informativo), interpretadas como uma



sondagem das contingências sociais envolvidas na escolha das marcas, conforme proposto por Oliveira-Castro et al. (2008).

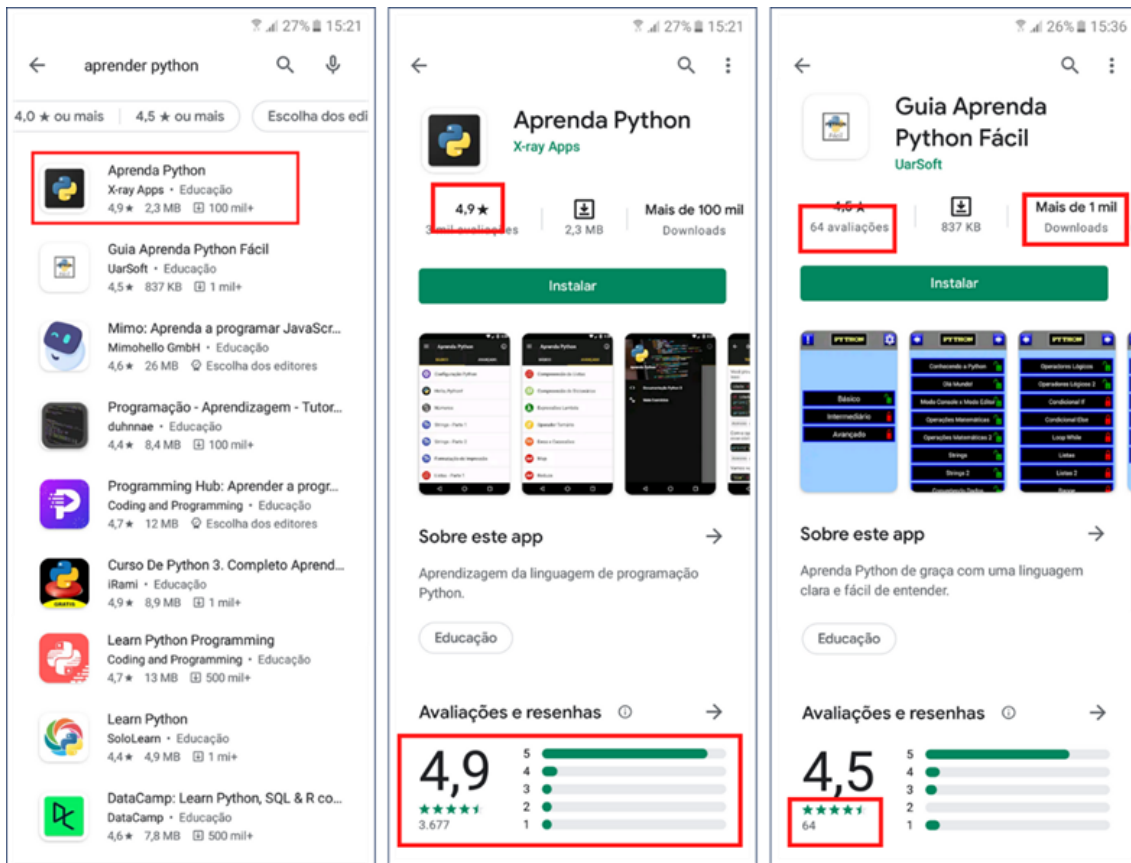
## **Métodos**

### **➤ Informações apresentadas na Google Play Store a serem consideradas**

Um panorama das informações apresentadas aos consumidores na Google Play Store pode ser observado na Figura 16. Quando um consumidor realiza uma busca por termos-chave o buscador retorna apps similares que possam estar relacionados ao termo, apresentando informações iniciais que são consideradas relevantes para escolha do app pelo consumidor, tais como: i) marca do app (ícone e nome); ii) categoria do app; iii) classificação por estrela do app; iv) tamanho do app; e v) quantidade de download já obtida pelo app. Ao clicar em um app específico, e ser direcionado para a página do app, essas informações são destacadas novamente.

Figura 16

Prints da loja de aplicativos



A classificação por estrelas é considerada pelo Google Play Console como uma medida de qualidade do app. A classificação consiste em uma avaliação do aplicativo que varia de 1 (muito ruim) a 5 (muito bom) realizada pelos usuários. A classificação média do app é uma informação de destaque na página do app. Assim, propomos que a classificação por estrelas é uma medida, plausível para mensurar a qualidade percebida da marca.

A quantidade de downloads e quantidade de avaliações do app têm sido consideradas como medidas de popularidade do app por especialistas. Uma vez que os valores apresentados na loja contabilizam apenas um download e/ou avaliação por conta Google Play, independente de reinstalações e instalação em múltiplos dispositivos. A Play Store classifica cada app em um intervalo de contagem de download que é apresentada para os consumidores [e.g., mais de 1 mil (intervalo de 1 mil a 10 mil downloads)], diferentemente da quantidade de avaliações que é apresentada em valor exato por ser menor e devido a sua importância (Google, 2020). Pois, em

geral, a quantidade de avaliações remete ao quantitativo de usuários que realmente tiveram alguma experiência com o app e expressaram sua opinião. Assim, propomos que a quantidade de downloads em conjunto com a quantidade de avaliações formam uma medida de conhecimento percebido da marca (familiaridade).

#### ➤ **Validação das medidas de conhecimento e qualidade percebida da marca**

Como forma de ampliar o rigor e aplicabilidade das medidas propostas, submeteu-se as medidas de mensuração proposta à validação por especialistas. A operacionalização dessa etapa foi realizada com auxílio da plataforma Google Form.

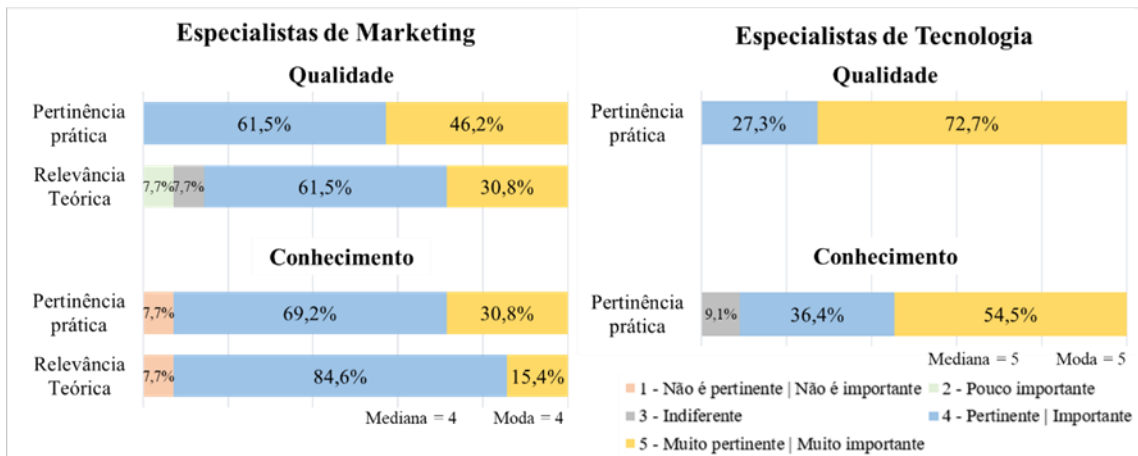
Devido à proposição de fatores com mensuração com dados secundários, o presente estudo optou por nortear a consulta com base em duas dimensões de avaliação – pertinência prática dos itens e relevância teórica em uma escala tipo Likert de cinco pontos, bem como foi deixado espaço para os especialistas deixarem sugestões e/ou críticas.

O instrumento de validação foi enviado por e-mail para 20 doutores pesquisadores de marketing do Brasil e Portugal para validação das duas dimensões, dos quais 14 (70%) avaliaram as medidas. Também foi enviado para 18 profissionais da área de tecnologia do Brasil e Japão, que atuam direta ou indiretamente com o desenvolvimento e/ou gestão de aplicativos mobile. Desses, 11 (61,1%) avaliaram as medidas propostas em relação à pertinência prática para o mercado mobile app. O quantitativo de juízes atendeu ao mínimo necessário sugerido por (Lynn, 1986).

Como pode ser observado na Figura 17, entre os especialistas de marketing a maioria acredita que as medidas propostas possuem pertinência prática e relevância teórica (mediana = 4). E, entre os especialistas de tecnologia, a maioria acredita que as medidas possuem muita pertinência prática (mediana = 5). Assim, considerou-se válido seguir com a proposta de criação de um *score* de força da marca composta pelas métricas de conhecimento e qualidade percebida, considerando os metadados da loja de aplicativos. Cabe acrescentar que as críticas e sugestões adicionais dos especialistas foram consideradas e as adequações apreciadas como pertinentes foram realizadas. Por exemplo, a consideração de aplicativos com pelo menos 500 download para evitar possíveis vies nas medidas.

**Figura 17**

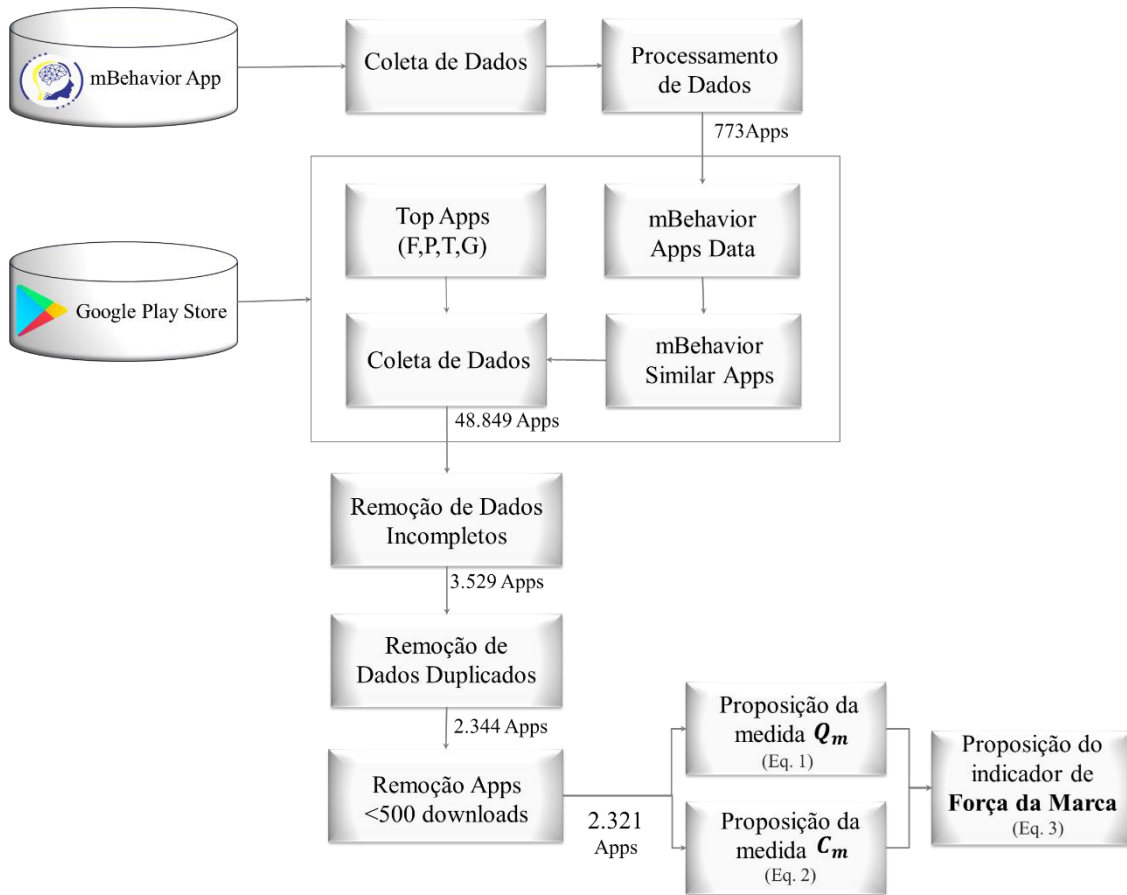
Validação das medidas de conhecimento e qualidade percebida de marcas de apps por especialistas



### ➤ Coleta de dados e medida da força da marca

Para a proposição do indicador de força da marca, optou-se por considerar como base a lista de apps de quatro categorias (Comunicação, Educação, Saúde & Fitness e Social) instalados nos smartphones com sistema operacional Android de 525 consumidores da região Centro-Oeste do Brasil. Os dados fazem parte do banco de dados, em construção, do projeto de pesquisa “M-Behavior”. A coleta dos dados ocorreu por meio do mBehavior App, um aplicativo mobile para Android desenvolvido para auxiliar no registro de dados anonimizados referente ao comportamento de uso de apps.

Considerando as categorias selecionadas, identificou-se 773 apps distintos nesta lista. Com base nessa relação foi realizado o processo de *data scraping* no Google Play Store utilizando a *RESTful API*. Com o intuito de ampliar a amostra, foram também coletados dados de apps similares a eles e os tops apps das categorias (tops gratuitos (F), pagos (P), *trending* (T) e *grossing* (G)), que resultaram em 48.849 apps. Após a remoção de apps que estavam com informações relevantes para as análises incompletas, apps duplicados e os app com menos de 500 downloads, a amostra final foi composta por 2.321 apps (ver Figura 18). Cabe acrescentar que por meio dessa API foi possível coletar os metadados em valores reais, além do formato apresentado aos consumidores.

**Figura 18***Estrutura da coleta e tratamento dos dados*

Como pode ser observado na Tabela 9, a amostra de aplicativos por categoria foi distribuída relativamente proporcional e representativa, considerando o total de aplicativos disponível no Google Play Store no período de coleta de dados.

**Tabela 9***Amostra de aplicativos por categoria*

	<b>Comunicação</b>	<b>Educação</b>	<b>Saúde e Fitness</b>	<b>Social</b>
Total de apps disponível*	69.287	283.155	103.203	60.114
Amostra	508	814	528	471

Nota. \*novembro/2020

Após a mineração dos dados, os mesmos foram tratados e o indicador da força da marca foi criado para cada marca de app intra-categoria, considerando as equações 1, 2 e 3. A Equação 1 correspondia à métrica de Qualidade percebida da marca ( $Q_m$ ), que foi medida com base na pontuação exata da “classificação por estrelas” de cada marca de app (e.g., Aprenda Python: S = 4,8629).

$$Q_m = \frac{S_m}{\frac{1}{n} \sum_{j=1}^n S_j} \quad (\text{Eq. 1})$$

Onde,

S é a pontuação da classificação por estrelas

m é a marca do aplicativo

j é a categoria

A métrica de Conhecimento da marca ( $C_m$ ) foi mensurada por meio de uma média harmônica dos quantitativos exatos de downloads e de avaliações transformados em log e padronizados pela categoria (Equação 2).

$$C_m = \frac{2 \left( \frac{\log D_m}{\left( \frac{1}{n} \sum_{j=1}^n \log D_j \right)} \right) \left( \frac{\log R_m}{\left( \frac{1}{n} \sum_{j=1}^n \log R_j \right)} \right)}{\frac{\log D_m}{\left( \frac{1}{n} \sum_{j=1}^n \log D_j \right)} + \frac{\log R_m}{\left( \frac{1}{n} \sum_{j=1}^n \log R_j \right)}} \quad (\text{Eq. 2})$$

Onde,

D é o quantitativo de downloads

R é o quantitativo de avaliações

m é a marca do aplicativo

j é o quantitativo da categoria

Com base nas equações (1) e (2), o indicador de força da marca foi calculado para cada marca, considerando o seu contexto competitivo (a categoria), a média dos valores de conhecimento e qualidade percebida da marca ( $MCQ_m$ ) (Equação 3).

$$MCQ_m = \frac{2 * Q_m * C_m}{Q_m + C_m} \quad (\text{Eq. 3})$$


Cabe mencionar que essa consideração se justifica com base no estudo de Porto (2019) que destaca a importância de se considerar a média do setor no indicador para uma aplicabilidade prática válida, uma vez que contribuiria para os gestores elaborarem metas mais realistas de score de força da marca.

## Resultados

Foram realizadas análises descritivas para verificar o ranking de score de força da marca entre e intra-categoria. O maior *score* de força da marca foi de uma marca da categoria de comunicação (1,38) e o menor foi de uma marca da categoria de Saúde & Fitness (0,37). Com exceção da categoria de comunicação, as demais apresentaram algumas *outliers*. Contudo, no geral, as marcas medianas apresentam pontuações próximas (Figura 19). As quatro marcas de apps com maiores e menores pontuações de força da marca podem ser conferidas na Tabela 10.

**Figura 19**

*Box-plot do indicador de força da marca por categoria*

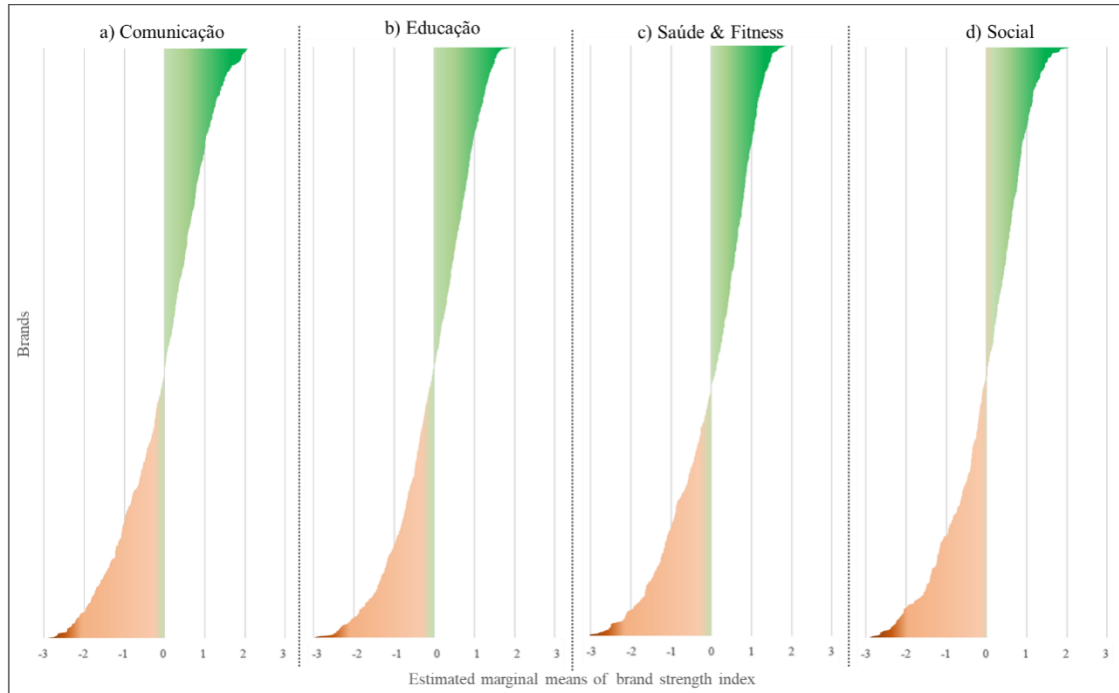


**Tabela 10***As quatro marcas com maior e menor indicador de força da marca por categoria*

Categoria	Ordem	Marcas	Score MCQ	SND
<b>Comunicação</b>	1	WhatsApp Messenger	1,38	2,12
	2	Google Duo: videochamadas de qualidade	1,37	2,05
	3	Messenger — mensagem e ligações de vídeo gratuitas	1,36	2,03
	4	Gmail	1,36	2,02
	505	Whats Tools - Smart Tool Kit for WA-Tools for chat	0,47	-2,65
	506	Conviver MRV	0,46	-2,69
	507	Meu atacadão	0,45	-2,74
	508	Vision: para pessoas com deficiência visual	0,41	-2,93
<b>Educação</b>	1	Duolingo: Inglês, Espanhol e mais!	1,37	2,09
	2	Photomath	1,35	1,94
	3	Cake: Pratique falar inglês grátis	1,32	1,79
	4	Memrise: aplicativo de idiomas grátis - Inglês	1,30	1,70
	811	Minha Biblioteca	0,48	-2,58
	812	CAEd Avaliação	0,43	-2,85
	813	Study Hub	0,41	-2,96
	814	Teclado Consciente TIM	0,40	-2,98
<b>Saúde &amp; Fitness</b>	1	Calendário Menstrual, Período Fértil e Ovulação	1,35	1,96
	2	Exercícios em Casa - Sem Equipamentos	1,32	1,81
	3	Barriga Tanquinho em 30 dias - Treino Abdominal	1,31	1,76
	4	Meu Calendário Menstrual Flo. Ovulação e Gravidez	1,30	1,68
	522	Zema Saúde	0,45	-2,75
	523	Barilife	0,43	-2,81
	527	Soul.me	0,39	-3,02
	528	Mindgrow	0,37	-3,14
<b>Social</b>	1	Instagram	1,37	2,08
	2	TikTok	1,36	2,03
	3	Facebook	1,33	1,84
	4	Snapchat	1,32	1,81
	398	Aparecida Saúde	0,47	-2,65
	399	GB Wasahp latest Version 2020	0,46	-2,67
	470	Reposter - Repost para Instagram	0,43	-2,83
	471	Homework Helper (Assistente de Estudo)	0,41	-2,92

A Figura 20 mostra as médias marginais estimadas do índice de força da marca em ordem de grandeza por categoria. Valores iguais a zero significam que a marca do app é igual à média do índice de força da marca intra-categoria. Um valor igual a um positivo (negativo) está em um desvio padrão acima (abaixo) da média. Um valor igual a dois positivo (negativo) está em dois desvios padrão acima (abaixo) da média.



**Figura 20***Ranking das marcas por categoria*

Em uma visão abrangente das categorias de apps consideradas, (i) 66,65% das marcas de apps se encontram a menos de um desvio padrão acima (abaixo) da média intra-categoria e (ii) apenas 4,27% das marcas apresentaram *score* de força da marca maior que dois desvios negativos e 0,30% das marcas possuem *score* maior que dois desvios positivos da média intra-categoria.

## Apêndice E – Resultados dos Modelos de Regressão Quantílica

**Tabela 11**
*Penetração (por aquisição) - Resultados da Regressão Quantílica dos modelos 1 e 2*

	$\tau = 0,05$		$\tau = 0,25$		$\tau = 0,50$		$\tau = 0,75$		$\tau = 0,95$	
Interceptar	0,016 (0,009)	-0,071*** (0,022)	-0,258**** (0,042)	-0,403**** (0,083)	0,211**** (0,009)	0,12**** (0,029)	-0,548** (0,254)	-0,633*** (0,248)	-2,002 (0,416)	-1,694 (1,055)
MCQ	0,091**** (0,016)	0,226**** (0,044)	0,888**** (0,080)	1,041**** (0,163)	0,103**** (0,018)	0,242**** (0,056)	1,983**** (0,488)	1,890**** (0,486)	6,438**** (0,797)	4,268** (2,071)
Idade do app		0,018**** (0,005)		0,049** (0,025)		0,014 (0,009)		0,163**** (0,075)		1,567**** (0,32)
país de origem		0,011 (0,007)		0,081**** (0,018)		0,019*** (0,006)		0,104 (0,054)		0,194 (0,230)

*Nota.* os números entre parênteses representam o erro padrão. Modelo 1 – sem controle; Modelo 2 – com controle  
 \*\*\*\* p<0,001; \*\*\* p<0,01; \*\* p<0,05; \* p<0,1

**Tabela 12**
*Penetração de uso - Resultados da Regressão Quantílica dos modelos 1 e 2*

	$\tau = 0,05$		$\tau = 0,25$		$\tau = 0,50$		$\tau = 0,75$		$\tau = 0,95$	
Interceptar	0,693**** (3E-11)	0,693**** (1E-09)	0,693**** (2E-11)	0,693**** (8E-09)	0,693**** (2E-11)	0,693**** (8E-11)	-0,394 (0,610)	-0,660 (0,691)	-1,636 (2,954)	-0,207 (1,286)
MCQ	-7E-11 (4E-11)	2E-09 (2E-09)	6E-11*** (3E-11)	1E-08 (1E-08)	4E-11 (3E-11)	9E-11 (1E-10)	2,281*** (0,895)	2,088** (1,047)	7,353* (4,339)	1,596 (1,949)
Idade do app		1E-09** (5E-10)		3E-09 (3E-09)		2E-11 (3E-11)		0,584** (0,246)		3,129**** (0,458)
país de origem		-9E-11 (3E-10)		2E-09 (2E-09)		2E-12 (2E-11)		0,117 (0,185)		-0,200 (0,345)

*Nota.* os números entre parênteses representam o erro padrão. Modelo 1 – sem controle; Modelo 2 – com controle  
 \*\*\*\* p<0,001; \*\*\* p<0,01; \*\* p<0,05; \* p<0,1

**Tabela 13***Market Share de uso - Resultados da Regressão Quantílica dos modelos 1 e 2*

	$\tau = 0,05$		$\tau = 0,25$		$\tau = 0,50$		$\tau = 0,75$		$\tau = 0,95$	
Interceptar	-0,064 (0,102)	-0,258** (0,129)	-0,389 (0,303)	-0,648** (0,327)	-1,110 (0,547)	-1,709*** (0,550)	-1,027 (1,057)	-0,299 (1,888)	-3,122 (3,999)	-0,649 (0,707)
MCQ	0,233 (0,150)	0,348* (0,196)	1,030** (0,444)	1,081** (0,495)	2,743*** (0,804)	2,770*** (0,834)	4,003*** (1,552)	1,106 (2,862)	11,364** (5,874)	1,203 (1,072)
Idade do app		0,181*** (0,046)		0,318** (0,116)		0,885*** (0,196)		2,035** (0,672)		5,909*** (0,252)
país de origem		0,104*** (0,035)		0,162* (0,088)		0,143 (0,147)		-0,098 (0,506)		0,247 (0,189)

Nota. os números entre parênteses representam o erro padrão. Modelo 1 – sem controle; Modelo 2 – com controle

\*\*\* p<0,001; \*\* p<0,01; \* p<0,05; p<0,1

**Tabela 14***Lealdade Comportamental - Resultados da Regressão Quantílica dos modelos 1 e 2*

	$\tau = 0,05$		$\tau = 0,25$		$\tau = 0,50$		$\tau = 0,75$		$\tau = 0,95$	
Interceptar	-0,114 (0,150)	-0,436 (0,093)	-0,344 (0,229)	-0,382 (0,222)	-0,574 (0,451)	-1,079 (0,368)	-0,137 (1,022)	0,564 (1,041)	-0,272 (1,284)	-0,780 (0,813)
MCQ	0,382* (0,220)	0,660*** (0,140)	1,006*** (0,336)	0,730** (0,336)	1,930*** (0,662)	1,837*** (0,557)	2,333 (1,501)	-0,021 (1,577)	4,249** (1,886)	3,393*** (1,231)
Idade do app		0,191*** (0,033)		0,355*** (0,079)		0,705*** (0,131)		1,139*** (0,371)		1,747*** (0,289)
país de origem		0,127*** (0,025)		0,087 (0,059)		0,263*** (0,098)		0,201 (0,279)		0,206 (0,218)

Nota. os números entre parênteses representam o erro padrão. Modelo 1 – sem controle; Modelo 2 – com controle

\*\*\* p<0,001; \*\* p<0,01; \* p<0,05; p<0,1

**Tabela 15***Penetração (por aquisição) - Resultados da Regressão de Quantílica com efeito moderador<sup>#</sup>*

<b>Categoria</b>	<b>Variável</b>	$\tau = 0,05$	$\tau = 0,25$	$\tau = 0,50$	$\tau = 0,75$	$\tau = 0,95$
Comunicação	Interceptar	0,174****	0,174****	-0,159	-3,286***	-5,783***
		(3E-09)	(2E-12)	(0,277)	(1,291)	(0,502)
	MCQ	6E-08****	1E-12	0,932***	3,998**	8,895**
		(4E-09)	(2E-12)	(0,350)	(1,636)	(0,635)
	Idade do app	-3E-09****	-3E-13	-0,036	0,168	0,321
	(4E-10)	(2E-13)	(0,036)	(0,167)	(0,065)	
	país de origem	5E-09****	-2E-13	0,061	0,111	-0,586
		(9E-10)	(5E-13)	(0,074)	(0,346)	(0,134)
Educação	Interceptar	0,174****	0,174****	0,174****	-0,138	-0,359
		(1E-12)	(3E-13)	(2E-09)	(0,100)	(1,172)
	MCQ	4E-12***	1E-13	5E-09***	0,727****	1,437
		(2E-12)	(3E-13)	(2E-09)	(0,119)	(1,395)
	Idade do app	-3E-13*	-9E-15	-1E-10	-0,013	0,032
	(2E-13)	(3E-14)	(2E-10)	(0,011)	(0,126)	
	país de origem	5E-13*	8E-14	7E-10**	0,077****	-0,059
		(3E-13)	(6E-14)	(3E-10)	(0,022)	(0,256)
Saúde & Fitness	Interceptar	0,174****	0,174****	0,174****	-0,487	-1,854
		(5E-11)	(2E-12)	(7E-09)	(0,437)	(1,164)
	MCQ	1E-10**	6E-12***	1E-08*	1,300***	2,986**
		(6E-11)	(2E-12)	(8E-09)	(0,507)	(1,351)
	Idade do app	1E-12	-2E-13	1E-10	-0,001	0,094
	(4E-12)	(2E-13)	(6E-10)	(0,038)	(0,102)	
	país de origem	1E-11	1E-12**	1E-09	0,062	0,635**
		(1E-11)	(5E-13)	(2E-09)	(0,100)	(0,266)
Social	Interceptar	0,174****	0,174****	0,174****	-1,580****	-5,899****
		(2E-12)	(1E-10)	(2E-08)	(0,481)	(0,784)
	MCQ	1E-11****	2E-10	2E-07****	1,702***	3,347****
		(3E-12)	(2E-10)	(3E-08)	(0,625)	(1,019)
	Idade do app	1E-13	-1E-11	-3E-09	0,125**	0,762****
	3E-13	(2E-11)	(3E-09)	(0,061)	(0,100)	
	país de origem	1E-12***	5E-12	0,148****	0,358***	0,442**
		(5E-13)	(4E-11)	(6E-09)	(0,133)	(0,216)

Nota. os números entre parênteses representam o erro padrão. <sup>#</sup>Modelo 4

\*\*\* p<0,001; \*\* p<0,01; \* p<0,05

**Tabela 16***Penetração de uso - Resultados da Regressão de Quantílica com efeito moderador<sup>#</sup>*

<b>Categoria</b>	<b>Variável</b>	$\tau = 0,05$	$\tau = 0,25$	$\tau = 0,50$	$\tau = 0,75$	$\tau = 0,95$
Comunicação	Interceptar	0,584 (1,649)	0,584 (5,991)	-6,273**** (1,325)	-13,587**** (3,184)	-13,094**** (2,142)
	MCQ	9E-10 (2,567)	1E-08 (9,328)	7,132**** (2,063)	12,649*** (4,958)	9,203*** (3,336)
	<i>Idade do app</i>	-4E-12 (0,198)	-3E-10 (,718)	0,268* (0,159)	0,805** (0,382)	1,215**** (0,257)
	<i>país de origem</i>	5E-11 (0460)	5E-10 (1,671)	0,174 (0,369)	1,813** (0,888)	2,253**** (0,597)
Educação	Interceptar	0,584**** (8E-11)	0,584 (1,516)	0,584 (1,475)	0,951 (1E-07)	2,434 (5,350)
	MCQ	-2E-11 (8E-11)	8E-12 (1,552)	3E-08 (1,511)	2E-07 (1E-07)	-5,104 (5,478)
	<i>Idade do app</i>	-9E-12 (1E-11)	-6E-13 (,205)	-9E-09 (,199)	-1E-09 (1E-08)	0,488 (,722)
	<i>país de origem</i>	3E-12 (2E-11)	-4E-12 (,308)	-6E-10 (,299)	-0,366 (2E-08)	-0,413 (1,085)
Saúde & Fitness	Interceptar	0,584**** (1E-08)	0,584**** (2E-10)	0,584 (2,229)	-0,349 (1,265)	-5,458**** (1,449)
	MCQ	-2E-08** (1E-08)	-2E-10 (2E-10)	3E-08 (2,133)	1,364 (1,211)	4,037**** (1,387)
	<i>Idade do app</i>	4E-09**** (1E-09)	1E-11 (2E-11)	6E-09 (,220)	0,035 (,125)	0,565**** (,143)
	<i>país de origem</i>	-2E-09 (2E-09)	-2E-11 (3E-11)	7E-09 (,369)	0,105 (,210)	1,200**** (,240)
Social	Interceptar	0,584**** (1E-08)	0,584 (,988)	-1,812*** (,573)	-4,185*** (1,309)	-4,213*** (1,636)
	MCQ	3E-09 (2E-08)	-5E-09 (1,385)	1,866** (,804)	3,774** (1,835)	2,082 (2,294)
	<i>Idade do app</i>	4E-09** (2E-09)	5E-11 (,139)	0,164** (,081)	0,387** (,185)	0,831**** (,231)
	<i>país de origem</i>	-1E-08*** (3E-09)	-1E-09 (,257)	0,285* (,149)	0,305 (,341)	-0,868** (,426)

*Nota.* os números entre parênteses representam o erro padrão. <sup>#</sup>Modelo 4

\*\*\*\* p<0,001; \*\*\* p<0,01; \*\* p<0,05; \* p<0,1

**Tabela 17***Market Share de uso - Resultados da Regressão de Quantílica com efeito moderador<sup>#</sup>*

<b>Categoria</b>	<b>Variável</b>	$\tau = 0,05$	$\tau = 0,25$	$\tau = 0,50$	$\tau = 0,75$	$\tau = 0,95$
Comunicação	Interceptar	-0,019**** (,005)	-0,049**** (,013)	-0,175*** (,056)	-1,920*** (,701)	-10,882**** (1,465)
	MCQ	0,012* (,007)	0,035* (,020)	0,094 (,088)	1,526 (1,092)	10,670**** (2,280)
	<i>Idade do app</i>	0,002*** (,001)	0,004** (,002)	0,018*** (,007)	0,134 (,084)	0,543*** (,176)
	<i>país de origem</i>	0,001 (,001)	0,002 (,004)	-0,006 (,016)	0,227 (,196)	2,424**** (,408)
Educação	Interceptar	0,035**** (2E-09)	0,035 (,309)	-0,124 (,229)	-0,646 (1,042)	0,680 (3,853)
	MCQ	3E-10 (2E-09)	8E-08 (,317)	0,227 (,234)	0,267 (1,067)	-7,425* (3,945)
	<i>Idade do app</i>	-2E-10 (2E-10)	-1E-08 (,042)	0,007 (,031)	0,115 (,141)	0,942* (,520)
	<i>país de origem</i>	1E-09**** (3E-10)	0,034 (,063)	0,087* (,046)	0,049 (,211)	-0,457 (,782)
Saúde & Fitness	Interceptar	4E-04 (2E-09)	-0,005 (,005)	-0,025* (,014)	-0,072** (,033)	0,445**** (,065)
	MCQ	1E-09 (2E-09)	0,002 (,005)	0,015 (,013)	0,031 (,031)	-0,436**** (,062)
	<i>Idade do app</i>	3E-10** (2E-10)	0,001 (,000)	0,003* (,001)	0,009*** (,003)	-0,002 (,006)
	<i>país de origem</i>	5E-10 (3E-10)	0,001 (,001)	0,001 (,002)	0,002 (,005)	-0,082**** (,011)
Social	Interceptar	-0,004 (,005)	-0,019* (,010)	-0,148**** (,041)	-0,168** (,080)	-4,099*** (1,223)
	MCQ	0,003 (,007)	0,025* (,015)	0,138** (,057)	0,060 (,112)	3,941** (1,715)
	<i>Idade do app</i>	4E-04 (,001)	0,001 (,001)	0,010 (,006)	0,026** (,011)	0,558*** (,173)
	<i>país de origem</i>	0,001 (,001)	0,002 (,003)	0,006 (,011)	-0,016 (,021)	-1,442**** (,318)

Nota. os números entre parênteses representam o erro padrão. <sup>#</sup>Modelo 4

\*\*\*\* p<0,001; \*\*\* p<0,01; \*\* p<0,05; \* p<0,1

**Tabela 18***Lealdade Comportamental - Resultados da Regressão de Quantílica com efeito moderador<sup>#</sup>*

<b>Categoria</b>	<b>Variável</b>	$\tau = 0,05$	$\tau = 0,25$	$\tau = 0,50$	$\tau = 0,75$	$\tau = 0,95$
Comunicação	Interceptar	-7,142****	-4,346**	-5,585**	-4,855*	-7,735****
		(1,826)	(2,095)	(2,309)	(2,747)	(1,332)
	MCQ	4,922*	-0,395	-3,880	-0,493	6,310***
		(2,843)	(3,262)	(3,595)	(4,277)	(2,074)
	Idade do app	0,619***	0,916****	1,583****	1,202****	1,170****
	(0,219)	(0,251)	(0,277)	(0,329)	(0,160)	
país de origem		0,828	0,074	-0,701	-0,823	-1,268****
		(0,509)	(0,584)	(0,644)	(0,766)	(0,371)
Educação	Interceptar	0,693	0,693	-0,331	-1,838	-5,193
		(1,387)	(3,342)	(1,770)	(1,122)	(3,155)
	MCQ	4E-11	2E-09	1,770	0,445	-0,297
		(1,420)	(3,422)	(1,812)	(1,149)	(3,230)
	Idade do app	-4E-12	-7E-10	0,050	0,500****	1,197***
	(,187)	(,451)	(,239)	(,151)	(,426)	
país de origem		1E-11	0,405	0,656*	0,629***	1,062
		(,281)	(,678)	(,359)	(,228)	(,640)
Saúde & Fitness	Interceptar	0,693****	-3,842**	-5,13**	2,873	5,062****
		(7E-09)	(1,768)	(2,361)	(2,857)	(1,555)
	MCQ	7E-09	3,189*	2,628	-3,379	3,811***
		(7E-09)	(1,692)	(2,259)	(2,734)	(1,488)
	Idade do app	1E-09*	0,371**	0,685***	0,34	-0,569****
	(7E-10)	(,175)	(,233)	(,282)	(,154)	
país de origem		2E-09	0,624**	0,877**	0,229	0,765***
		(1E-09)	(,293)	(,391)	(,473)	(,258)
Social	Interceptar	0,693	-0,476	-5,196*	-1,824	-4,536****
		(,748)	(1,717)	(2,694)	(2,963)	(1,068)
	MCQ	3E-08	1,790	7,557**	3,024	2,792*
		(1,049)	(2,407)	(3,777)	(4,155)	(1,498)
	Idade do app	-4E-10	0,084	0,267	0,441	1,010****
	(,106)	(,242)	(,380)	(,418)	(,151)	
país de origem		-2E-09	-0,388	0,038	-0,889	-0,795***
		(,195)	(,447)	(,702)	(,772)	(,278)

Nota. os números entre parênteses representam o erro padrão. <sup>#</sup>Modelo 4

\*\*\*\* p<0,001; \*\*\* p<0,01; \*\* p<0,05; \* p<0,1

## Apêndice F – Tipologia de configuração de intensidade de acesso ao longo do dia

### Métodos

Considerando que estudos anteriores apontam que há diferenças comportamentais de uso de apps no decorrer do dia (*e.g.*, Deng et al., 2019; Guan et al., 2019; Li et al., 2020; Zhu et al., 2018), o presente estudo optou pela proposição de uma tipologia de configuração de intensidade de acessos aos apps ao longo do dia. Para tanto, os dados foram tratados em quatro etapas:

- I. Os horários exatos dos acessos de cada app foram registrados com base nos logs de acessos padronizados (considerando o fuso-horário do dispositivo móvel);
- II. Os acessos foram sumarizados e agrupados em quatro janelas temporais em um ciclo de 24 horas: (J<sub>1</sub>) entre 6h e 11h59, (J<sub>2</sub>) 12h e 17h59, (J<sub>3</sub>) 18h e 23h59 e (J<sub>4</sub>) 00h e 5h59;
- III. Foram calculadas as proporções de acesso aos apps por janela temporal ao dia; e
- IV. Por fim, as proporções de acessos por janela temporal foram padronizadas em dois níveis de intensidade de acesso (definidos pelo 2º quartil) – (1) houve baixo (ou nenhum) acesso no intervalo de horário J<sub>x</sub> e (2) houve alto acesso no intervalo de horário J<sub>x</sub>.

Levando em consideração que um mesmo indivíduo pode apresentar padrões de uso diferentes no decorrer do período investigado (*i.e.*, 30 dias), foi considerado como amostra os 3.030 registros para as quatro categorias em conjunto (Comunicação, Educação, Saúde & Fitness e Social). Assim, a proposição da tipologia revela padrões de configurações diárias geral para esse conjunto de categorias.

Após o tratamento dos dados foi realizada uma análise descritiva dos dados. E, posteriormente, foi realizada a análise de cluster pelo método de K-means que consiste em uma análise multivariada, cujo objetivo é separar os dados em grupos com maior distinção possível e minimizar a variação intragrupo. Para a seleção do melhor número de clusters foram utilizados como critérios as análises de cotovelo (método experimental) e de silhueta (método teórico) (cf. Hamerly & Elkan, 2004). Cabe acrescentar que a análise de cluster foi realizada com os dados da Etapa III do tratamento de dados.

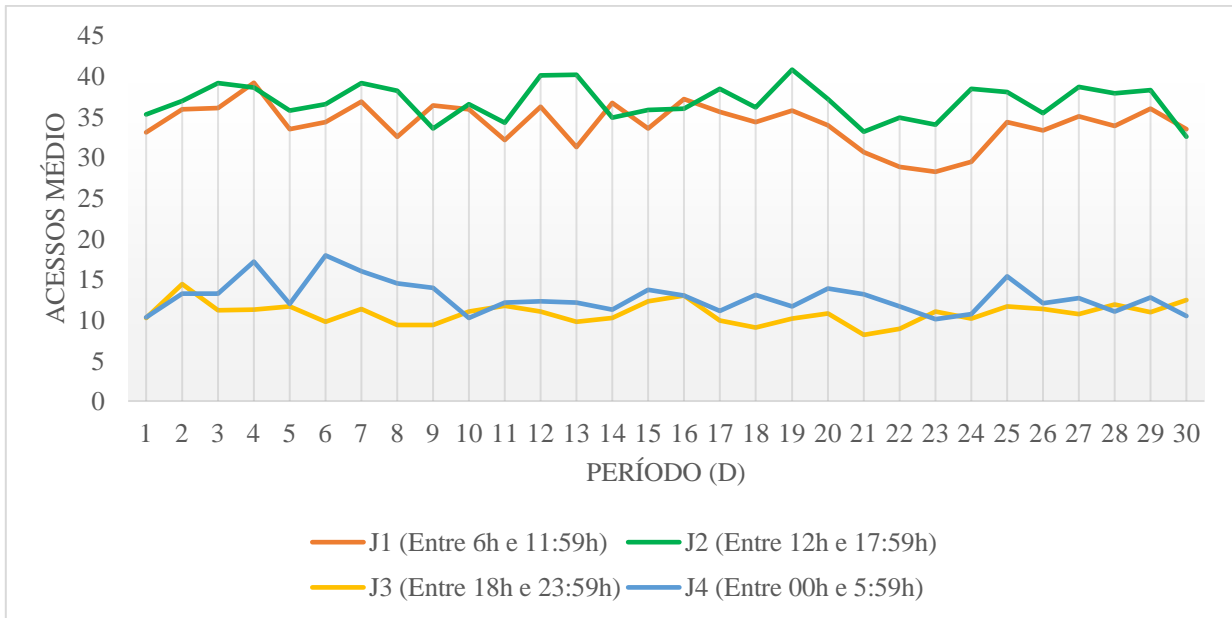


## Resultados

Na Figura 2 pode ser observada a tendência de acessos médios no período por janela temporal. Como pode ser observado nos períodos da manhã ( $J_1$  – 34,1 acessos médios;  $dp.$  31,5) e da tarde ( $J_2$  – 36,8 acessos médios;  $dp.$  34,3) a uma similaridade na tendência média de frequência de acessos aos apps que compõem o conjunto de categorias amostradas. Tendência parecida ocorre com os períodos da noite ( $J_3$  – 10,8 acessos médios;  $dp.$  17,6) e da madrugada ( $J_4$  – 12,7 acessos médios;  $dp.$  16,8).

**Figura 21**

*Acesso médio por janela temporal/dia*

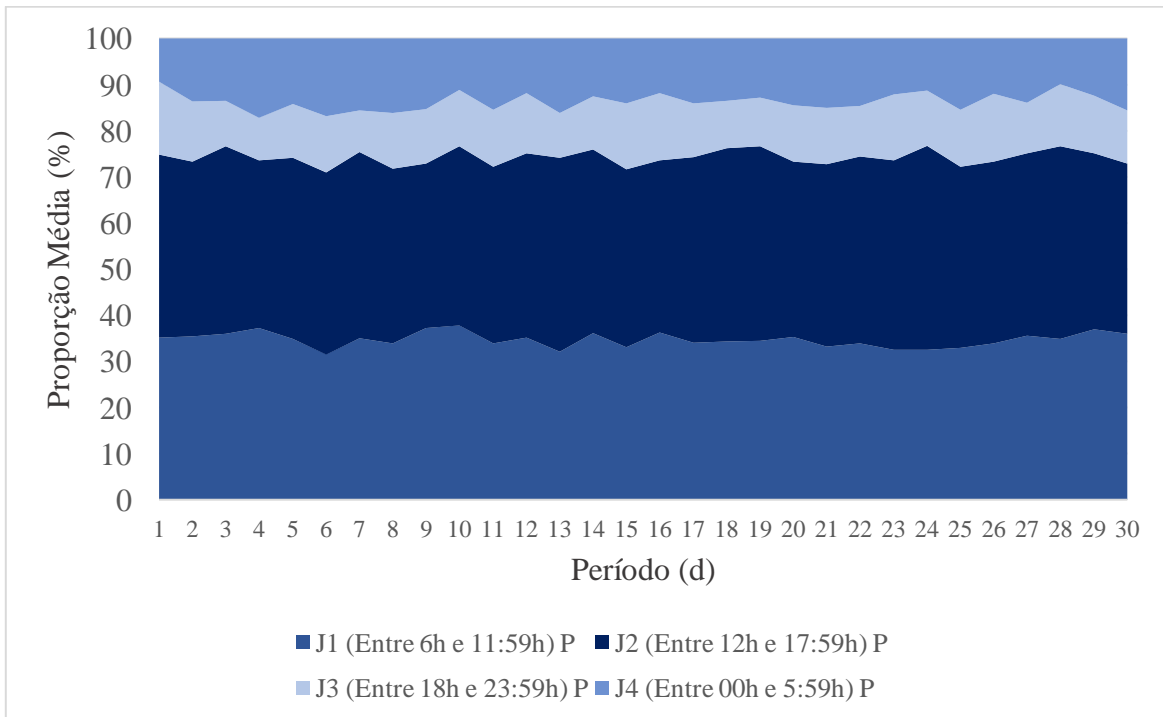


Quando verificada a proporção de frequência de acessos ao longo do período, constata-se que durante o dia ( $J_1 \cap J_2$ ) há uma maior proporção média de frequência de acessos (74,18% cumulativo) (ver Figura 22). Nos intervalos subsequentes ( $J_3 \cap J_4$ ), a proporção média de frequência de acessos reduz consideravelmente. Essa tendência de redução de comportamento móvel é esperada, pois geralmente as pessoas começam a descansar e dormir em algum momento desse intervalo ( $J_3 \cap J_4$ ) (Li et al., 2020). Tendo isso em vista, acredita-se que a configuração de intensidade de acessos ao longo do dia seria melhor interpretada por meio de níveis de proporção

de acesso em cada janela temporal, uma vez que a tendência se apresentasse relativamente constante.

**Figura 22**

*Proporção de acesso por janela temporal/dia*



Para a escolha do melhor quantitativo de clusters, para a proposição da tipologia, foram considerados os critérios de melhor pontuação da silhueta, distribuição e a curva do cotovelo (Hamerly & Elkan, 2004), optando-se, assim, pelo modelo com 3 clusters (ver Figura 23).

**Figura 23**

*Análise de Cluster*

<b>K-Means Clustering</b>					
Clusters	N	R <sup>2</sup>	AIC	BIC	Silhouette
3	3030	0,454	6633,600	6705,790	0,340
<b>Cluster Information</b>					
	Cluster	1	2	3	
Size		1826	953	251	
Explained proportion within-cluster heterogeneity		0,603	0,315	0,083	

Cluster Description								
Cluster	Proporção 1		Proporção 2		Proporção 3		Proporção 4	
	Entre 6h e 11:59h		Entre 12h e 17:59h		Entre 18h e 23:59h		Entre 00h e 5:59h	
	$\bar{X}$	Me	$\bar{X}$	Me	$\bar{X}$	Me	$\bar{X}$	Me
<b>1</b>	20,138	21,951	63,483	59,649	10,217	7,500	6,162	1,020
<b>2</b>	45,362	43,708	28,838	30,769	6,716	3,448	19,084	16,154
<b>3</b>	12,375	10,274	25,764	29,73	58,050	50,000	3,811	0,000

Cabe salientar que os resultados da análise de cluster foram interpretados levando em consideração a Etapa IV do tratamento dos dados. Essa tratativa permitiu retratar o padrão de uso de apps intra e entre janelas temporais, possibilitando, assim, sintetizá-los em três padrões de intensidade de acessos aos apps que compõem o conjunto de categorias amostradas ao longo do dia (ver Figura 24).

**Figura 24**

*Tipologia de configuração de intensidade de acessos aos apps ao longo do dia – Síntese*

Cluster	Interpretação
<b>1 – Padrão Alvorada (60,3%)</b>	Alta proporção de acesso de manhã e de madrugada; Baixo (ou nenhum) acesso à tarde e à noite.
<b>2 – Padrão Vespertino (31,5%)</b>	Baixo (ou nenhum) acesso de manhã e de madrugada; e Alto acesso à tarde e à noite.
<b>3 – Padrão Noturno (8,3%)</b>	Baixo (ou nenhum) acesso de manhã, à tarde e de madrugada; e Alto acesso à noite.

Conforme pode ser observado na Figura 24, o Cluster 1 – “Padrão Alvorada”, sua configuração é melhor representada por alta proporção de acesso de manhã e de madrugada e baixo (ou nenhum) acesso à tarde e à noite. Esse padrão foi o mais recorrente dado a amostra (60,3%) e é caracterizado com intensidade de acesso mais elevada quando comparado com os demais clusters.

## **Apêndice G – História de aprendizagem do consumidor: proposição de perfis latentes de experiência mobile do consumidor**

### **Contextualização**

Em termos do arcabouço teórico-metodológico do BPM, a história de aprendizagem do consumidor resulta das escolhas passadas relacionadas a um determinado tipo de consumo e as consequências de reforço ou punição que eles tiveram. Ela é evocada em configurações de cenários de consumos semelhantes em ocasiões subsequentes/presentes. E, por sua vez, sinaliza quais estímulos neutros presentes no cenário serão transformados em estímulos discriminativos e o que funcionará como reforço/punição (Foxall, 2015, 2016; Foxall & Sigurdsson, 2013). Neste sentido, a história de aprendizagem modela a individualidade do consumidor, isto é, a sua heterogeneidade.

As características psicológicas, sociais e comportamentais do consumidor – como traços de personalidade, características sociodemográficas, padrões de envolvimento sociais e comportamento anterior do consumidor (*e.g.* ser um consumidor pesado de uma determinada categoria de produto) – podem ser interpretadas como variáveis proximais de história de aprendizagem, se entendidas como conceitos disposicionais (Ryle, 2009), uma vez que elucidam diferenças entre os indivíduos quanto à exposição a múltiplas variedades e magnitudes de estímulos ao longo da vida, revelando, assim, pistas acerca dos tipos de eventos aos quais o consumidor foi exposto e sobre o repertório decorrente de uma história de reforçamento (punição) relacionada a essa exposição (Foxall, 2016; Foxall et al., 1998).

No contexto do comportamento de uso de marcas de aplicativos, a experiência mobile do consumidor – nível de uso de dispositivo móvel, o repertório inicial de marcas de aplicativos por nível de reforço informativo programado e a inovatividade do consumidor – poderia ser interpretada como diversidades da história de aprendizagem do consumidor que tendem a influenciar o comportamento.

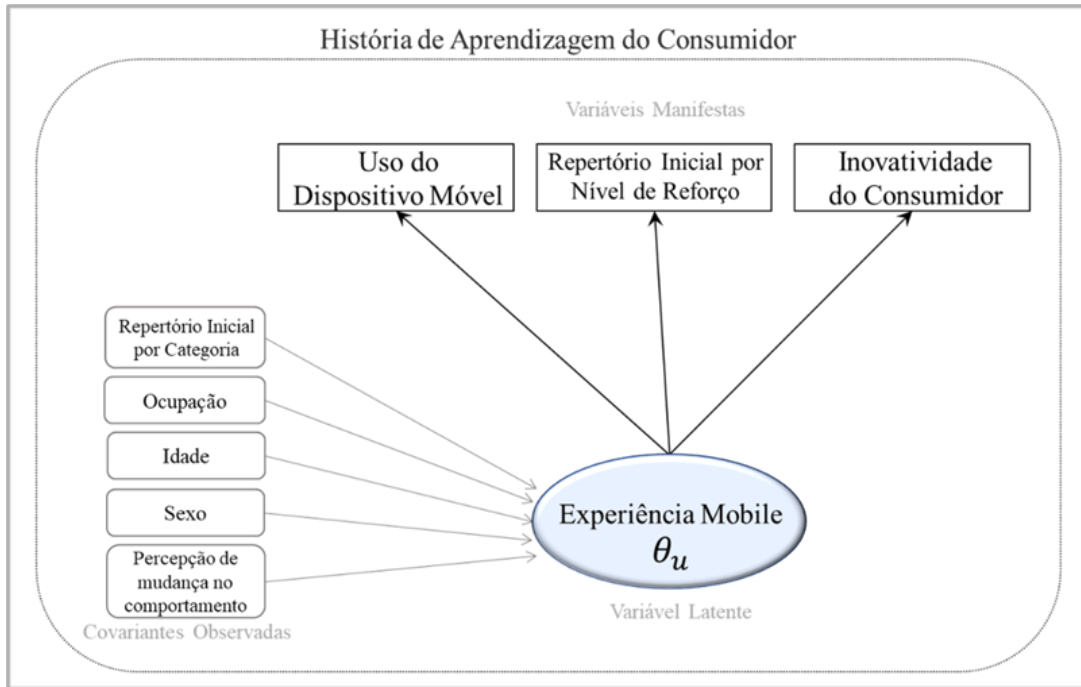
Segundo Ding et al. (2020), embora as análises de mercado agregadas tendam a mascarar a heterogeneidade, as análises no nível do consumidor geralmente requerem grandes quantidades de dados, tornando-se relativamente inviáveis, a depender do contexto focal, uma vez que cada consumidor individual é único em termos de suas características demográficas, preferências,

respostas a estímulos de marketing, processos de tomada de decisão etc. Para resolver os atribulados esforços de coleta de dados, procedimentos Bayesianos e classes latentes têm sido sugerido para capturar a heterogeneidade do consumidor (Ding et al., 2020; Floh et al., 2014; Ju et al., 2021).

Modelos de análise de classes latentes (LCA – *Latent Class Analysis*) apresentam a particularidade de detectar a heterogeneidade, não observada na especificação do modelo, de uma população, localizando o menor número possível de grupos presentes no universo em estudo. Assim, os indivíduos dos quais cada segmento é composto se originam de uma combinação de distribuições de probabilidade, isto é, uma segmentação *post hoc* (Millán et al., 2016; Wedel & Kamakura, 2000).

Diante do exposto, considerando que o efeito da experiência passada do consumidor, podem resultar em perfis latentes não observados. O presente estudo pretende contribuir para o avanço da literatura analítico-comportamental, sugerindo a proposição de perfis latentes de experiência mobile dos consumidores, mensurando, assim, o efeito conjunto de variáveis da história de aprendizagem do consumidor.

Nesta perspectiva propõe-se identificar perfis latentes de experiência mobile do consumidor, em uma perspectiva analítica-comportamental. Conforme pode ser observado na Figura 25, as variáveis manifestas são o nível de uso de dispositivo móvel, tamanho do repertório inicial de marcas de aplicativos por nível de reforço informativo programado e a inovatividade do consumidor. Além disso, busca-se explorar possíveis predições de probabilidade de o indivíduo pertencer à classe, incluindo variáveis proximais que remetem aos efeitos acumulados de exposição a contingências passadas (Foxall & Sigurdsson, 2013). Covariantes como: características sociodemográficas – sexo, idade e ocupação; comportamental que indica preferências – tamanho do repertório inicial de aplicativos por categoria; e perceptiva de evento motivador – percepção de mudança no uso de smartphone e aplicativos após o início da pandemia do Covid-19 (Beaunoyer et al., 2020).

**Figura 25***Modelo de Análise de Classes Latentes***Métodos**

Segundo Hagenaars e Mccutcheon (2002), o modelo de LCA base é definido por indicadores categóricos com o pressuposto de independência local, ou seja, as variáveis manifestas são independentes. As variáveis que integraram o modelo e sua codificação podem ser observadas na Figura 26.

Figura 26

Variáveis consideradas para a análise de perfil latente de experiência mobile do consumidor

Variável	Codificação	Análise Descritiva
<b>Uso de dispositivo móvel</b>	Foi contabilizado o uso diário do consumidor no período amostrado. Esse valor é referente ao tempo diário em segundos de tela ligada/smartphone desbloqueado. Em um segundo momento, foi calculado o tempo médio diário de uso de smartphone, considerando o intervalo amostral. Por fim, esse tempo médio foi classificado em três níveis, são eles: (1) Uso Leve (2) Uso Moderado (3) Uso Pesado	36,6% dos consumidores possuíam um uso pesado de smartphone por dia.
<b>Repertório inicial por nível de reforço informativo programado</b>	Com base na lista de apps instalados no smartphone do consumidor, na data mais recente antes do intervalo amostrado, a marca dos aplicativos foi classificado de acordo com o seu nível de reforço informativo programado (ver Apêndice D). Posteriormente, o quantitativo de marcas de apps de cada nível foi agrupado em dois tamanhos (considerado o segundo quartil): (0) Não possui repertório este nível (1) Repertório Pequeno (2) Repertório Grande	Dentre os consumidores, predominou um repertório inicial pequeno por nível de reforço informativo programado. Isto é, 52,5% de baixo, 44,6% médio e 54,5% alto nível de reforço informativo são consumidores com repertório inicial pequeno.
<b>Inovatividade do Consumidor</b>	A inovatividade do consumidor foi mensurada por intermédio de uma escala Likert de 7 pontos, variando de 1 (Discordo totalmente) a 7 (Concordo totalmente) com cinco fatores, adaptada de Agarwal e Karahanna (2000) e Agarwal e Prasad (1998), a saber: IN1. Eu sei mais sobre novos aplicativos do que meus amigos. IN2. Se eu soubesse de um novo aplicativo interessante, eu procuraria experimentá-lo. IN3. Entre os meus amigos, geralmente sou o(a) primeiro(a) a experimentar novos aplicativos. IN4. Eu gosto de experimentar novos aplicativos, mesmo que eu não conheça ninguém que tenha usado antes. IN5. Entre os meus amigos, geralmente sou o(a) último(a) a experimentar novos aplicativos. A pontuação média foi classificada em três níveis: (1) Baixa Inovatividade (2) Moderada Inovatividade (3) Alta Inovatividade	37,6% apresentavam uma baixa inovatividade.

Para implementação do modelo, utilizou-se o módulo snowRMM/poLCA (Linzer & Lewis, 2021; Seol, 2020) do *software* Jamovi (The Jamovi project, 2021). Optou-se pelo mesmo, pois permite respostas contínuas, binárias, categóricas, inserção de números de repetição de ajuste no modelo e as análises podem ser realizadas para variáveis dicotômicas quanto politômicas.

Foi estimado um modelo de duas a seis classes. Com base nos índices de ajuste desses seis modelos, a solução de classe mais ótima foi selecionada. Os índices do BIC (*Bayesian Information*

*Criterion*) e AIC (*Akaike Information Criterion*) dos modelos foram comparados, considerando que, para ambos, os índices valores mais baixos indicam um melhor ajuste (Linzer & Lewis, 2011; Vrieze, 2012). Foi averiguado o índice de entropia de cada modelo, um valor maior indica que os indivíduos foram classificados com mais confiança (van de Schoot et al., 2017). O p-valor do teste de razão de verossimilhança foi calculado. Um p-valor abaixo de 0,05 indica uma melhoria significativa do ajuste do modelo atual em relação ao modelo com uma classe a menos (Nylund et al., 2007).

A fim de segmentar os consumidores por experiência mobile, considerando diferentes elementos da sua história de aprendizagem, o modelo foi dividido em três etapas (Vermunt, 2010). Na primeira etapa desta abordagem, foi aplicado o modelo multivariado de classe latente, onde é possível classificar os grupos e identificar quais são as características predominantes de cada classe. Na segunda etapa, os participantes foram atribuídos às classes, por meio de uma análise dos seus atributos, tornando-se realizável assinalar em qual classe tinha maior probabilidade de pertencerem.

Na terceira etapa, foi realizada uma regressão logística binomial, com o propósito de identificar quais covariantes tinham influência na composição das classes latentes emergentes (Nylund-Gibson & Choi, 2018). Foram adicionadas ao modelo cinco variáveis em acréscimos individuais (ver Figura 27).



**Figura 27***Possíveis covariantes do perfil latente*

Variável	Codificação	Análise Descritiva
Repertório Inicial por Categoria	Com base na lista de apps instalados no smartphone do consumidor, na data mais recente antes do intervalo amostrado, a marca dos aplicativos foram agrupadas de acordo com a sua categoria original registrada na Google Play Store. Posteriormente, o quantitativo por categoria foi classificado em dois tamanhos (considerado o segundo quartil): (0) não possui repertório desta categoria (1) Repertório Pequeno (2) Repertório Grande	Dentre os consumidores predominou um repertório inicial pequeno por categoria. Isto é, 68,3% de Comunicação, 46,5% de Educação, 49,5% de Saúde & Fitness e 55,4% de Social são consumidores com repertório inicial pequeno intra-categoria.
Ocupação	(1) Não trabalha (Dona(o) de casa / Atualmente desempregado(a)/ Pensionista/Aposentado(a)) (2) Estuda (Estudante/Universitário(a)) (3) Estuda e trabalha (4) Trabalha	44,6% dos consumidores estudam e trabalham.
Sexo	(0) Feminino (1) Masculino	58,4% dos consumidores eram do sexo feminino.
Idade	Faixa etária: (1) ≤ 20 anos (2) 21 a 30 anos (3) > 30 anos	46,5% dos consumidores tinham entre 21 e 30 anos.
Percepção de mudança no uso de smartphone e apps após o início da pandemia do Covid-19	A percepção de mudança no uso de smartphone e aplicativos após o início da pandemia do Covid-19 – entendida como evento passado, devido a coleta de dados ter ocorrido em um período considerável posterior ao início da pandemia no Brasil – foi mensurada por meio de duas perguntas:  Após o início da pandemia (COVID-19) no Brasil, você acredita que aumentou o seu tempo de uso diário do seu smartphone? (caso afirmativo) Em uma escala de 1 a 7, o quanto você acredita que aumentou o seu tempo de uso diário do seu smartphone?  Após o início da pandemia (COVID-19) no Brasil, você está utilizando com mais frequência aplicativos no seu smartphone? (caso afirmativo) Em uma escala de 1 a 7, o quanto você acredita que aumentou a sua frequência de uso de aplicativos no seu smartphone?  A pontuação média foi calculada e classificada em três níveis: (1) Pouca (ou nenhuma) mudança (2) Moderada mudança (3) Alta mudança	38,6% dos consumidores relataram que houve nenhuma ou pouca mudança no uso de smartphone e apps após o início da pandemia do Covid-19.

## Resultados

A Tabela 19 apresenta as estatísticas de qualidade de ajuste para as soluções de classe latente de um a seis. A solução de duas classes apresentou o menor valor de AIC e BIC e maior  $\chi^2$ . Portanto, a solução de duas classes foi selecionada como o modelo mais adequado.

**Tabela 19**

*Estatísticas de adequação para modelos de uma a seis classes*

Classes	AIC	BIC	Entropia <sup>#</sup>	Gsq	$\chi^2$	<i>p</i>
1	-	-	-	-	-	-
2	1020	1101	4,75	126	135	<0,001
3	1040	1163	4,67	115	120	<0,001
4	1054	1219	4,59	96,8	98	<0,001
5	1077	1284	4,54	87,4	89	<0,001
6	1101	1349	4,49	79,2	78,6	<0,001

*Nota.* <sup>#</sup>entropia não normalizada (varia 0 ao  $\infty$ ).

Os resultados do modelo LCA são apresentados na Tabela 20 A Classe 1 – “Consumidores Mobile Menos Experientes” apresentou o menor envolvimento com aplicativos por apresentar maior probabilidade de consumidores com baixo uso de dispositivo móvel (37,4%), bem como maior probabilidade de ter baixa inovatividade (43,5%). Em relação a probabilidade de tamanho de repertório inicial por reforço, foi melhor representada por: Baixo Reforço – 55% de não possuir repertório; Médio Reforço – 70,3% de não possuir repertório; e Alto Reforço – 82,4% de possuir repertório pequeno. De modo geral, os consumidores que compõem a classe tendem a ter um repertório pequeno de aplicativos e que, por sua vez, é predominantemente composto por marcas com alta magnitude de reforço.

**Tabela 20**  
*Probabilidade estimada de classe*

Variáveis		Classe 1	Classe 2
		(n=43; 42,2%)	(n=58; 57,8%)
		<i>P</i>	<i>P</i>
Uso de dispositivo móvel	(1) Uso Leve	0,374	0,241
	(2) Uso Moderado	0,318	0,351
	(3) Uso Pesado	0,309	0,408
Inovatividade do Consumidor	(1) Baixa	0,435	0,333
	(2) Moderada	0,283	0,273
	(3) Alta	0,282	0,394
Repertório Inicial de baixo reforço	(0) Não possui	0,550	0,027
	(1) Pequeno	0,450	0,580
	(2) Grande	0,000	0,394
Repertório Inicial de médio reforço	(0) Não possui	0,703	0,070
	(1) Pequeno	0,263	0,578
	(2) Grande	0,034	0,352
Repertório Inicial de alto reforço	(0) Não possui	0,000	0,000
	(1) Pequeno	0,824	0,341
	(2) Grande	0,176	0,659

A Classe 2 – “Consumidores Mobile Mais Experientes” – representa um perfil que tende a ter um maior envolvimento com aplicativos por apresentar maior probabilidade de consumidores com uso pesado de smartphone (40,8%), bem como maior probabilidade de ter alta inovatividade (39,4%). No que tange a probabilidade de tamanho de repertório inicial por reforço, a classe foi mais bem representada por: Baixo Reforço – 58% de possuir repertório pequeno e 39,4% de possuir repertório grande; Médio Reforço – 57,8% de possuir repertório pequeno e 35,2% de possuir repertório grande; e Alto Reforço – 65,9% de possuir repertório grande. De modo geral, os consumidores que compõem a classe tendem a ter um maior repertório de marcas de aplicativos e com maior variedade de reforço.

Após a atribuição dos consumidores nas classes de acordo com a sua maior probabilidade de pertença. Foram testados cinco modelos de regressão logística binomial para verificar qual possui o melhor ajuste preditivo. Para tanto, foi acrescida uma variável concomitante por vez. A escolha do modelo deu-se por meio da verificação da sua qualidade à priori. De modo que considerou-se os modelos que rejeitassem a hipótese nula e ficasse com a hipótese alternativa que

diz que o ajuste do modelo atual é diferente deste modelo com nenhum preditor. Devido todos os modelos propostos rejeitaram a hipótese nula, foi considerado o *pseudo-R* de Nagelkerke's maior que 80% e o menor AIC (Fox & Weisberg, 2020). Com base nesses critérios o Modelo 4 apresentou o melhor ajuste, conforme pode ser verificado na Tabela 21.

**Tabela 21**  
*Medidas de ajuste do modelo*

Model	Desvio	AIC	BIC	R <sup>2</sup> N	Overall Model Test		
					$\chi^2$	df	p
1	55,4	65,4	78,5	0,747	81,7	4	< 0,001
2	51,4	65,4	83,7	0,77	85,7	6	< 0,001
3	41,7	61,7	87,8	0,823	95,5	9	< 0,001
4	38,2	60,2	89	0,841	98,9	10	< 0,001
5	38,0	64,0	98,0	0,842	99,1	12	< 0,001

Na Tabela 22 são apresentados os resultados específicos do Modelo 4 que recomenda a inclusão de todas as covariantes, exceto idade. O modelo não mostrou multicolinearidade, pois os valores de tolerância foram maiores que 0,1 e os de VIFs apresentaram ser menores que 10. A Classe 1 – “Consumidores Mobile Menos Experientes” - foi designada como referência.

**Tabela 22**  
*Resultados das estimativas*

Variáveis	$\beta$	SE	p	VIF	Tolerância
Intercepto	-23,166	6,877	< 0,001***		
Categoria de Comunicação	0,783	0,638	0,219	1,23	0,814
Categoria de Educação	4,556	1,583	0,004**	1,630	0,615
Categoria de Saúde & Fitness	1,643	0,625	0,009**	1,26	0,792
Categoria de Social	2,388	0,831	0,004**	2,05	0,487
Percepção de mudança no uso de smartphone e apps após o início da pandemia do Covid-19:				1,410	0,709
Pouca (ou nenhuma) mudança – Alta mudança	-3,149	1,442	0,029*		
Moderada mudança – Alta mudança	-4,707	1,956	0,016*		
Ocupação:				1,260	0,792
Não trabalha – Estuda	4,801	2,924	0,101		
Estuda e trabalha – Estuda	4,439	1,893	0,019*		
Trabalha – Estuda	4,963	2,112	0,019*		
Sexo: Masculino – Feminino	1,951	1,161	0,093	1,390	0,719

*Nota.* As estimativas representam as chances de log de "Classes = 2" vs. "Classe = 1

Os resultados apontam que indivíduos com maior repertório inicial da categoria de Educação, Saúde & Fitness e Social possuem 4,56, 1,64 e 2,39 vezes, respectivamente, mais chance de pertencer a Classe 2 – “Consumidores Mobile Mais Experientes” - do que a Classe 1 – “Consumidores Mobile Menos Experientes”. A covariável ocupação também demonstrou uma influência significativa sobre os dois perfis, - indivíduos que estudam e trabalham (4,44 vezes) e os que somente trabalham (4,96 vezes) possuem mais chances de pertencer a classe dos mais experientes do que aqueles que somente estudam.

Em relação a mudança no uso do smartphone e aplicativos depois do início da pandemia, observou-se que consumidores que não perceberam mudança ou identificou pouca mudança (-3,15 vezes) e os que perceberam uma mudança moderada (-4,71 vezes) no uso do seu smartphone e aplicativos após o início da pandemia têm menos chance de fazer parte da Classe 2 – “Consumidores Mobile Mais Experientes” - quando comparado com aqueles que observaram alta mudança de uso.