

UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE DE
RIBEIRÃO PRETO
DEPARTAMENTO DE ADMINISTRAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO DE ORGANIZAÇÕES

GUILHERME GOMES CARDIM MATTOS

A influência de estratégias de marketing nas vendas de chocolate ao longo da pandemia de COVID-19: estudo de uma empresa multinacional que atua no mercado brasileiro.

ORIENTADORA: PROF.^a DR.^a MARINA
TOLEDO LOURENÇÃO ROCHA

RIBEIRÃO PRETO
2023

Prof. Dr. Carlos Gilberto Carlotti Junior
Reitor da Universidade de São Paulo

Prof. Dr. Fabio Augusto Reis Gomes
Diretor da Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto

Prof. Dr. João Luiz Passador
Chefe do Departamento de Administração

Profa. Dra. Janaina de Moura Engracia Giraldi
Coordenador do Programa de Pós-Graduação em Administração de Organizações

GUILHERME GOMES CARDIM MATTOS

A influência de estratégias de marketing adotadas nas vendas de chocolate ao longo da pandemia de COVID-19: estudo de uma empresa multinacional que atua no mercado brasileiro.

Dissertação apresentada ao Programa de Pós-Graduação em Administração de Organizações da Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto da Universidade de São Paulo, para obtenção do título de Mestre em Ciências. Versão corrigida. A original encontra-se disponível no Serviço de Pós-Graduação da FEA-RP/USP

ORIENTADORA: PROF.^a DR.^a MARINA
TOLEDO LOURENÇÃO ROCHA

RIBEIRÃO PRETO
2023

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

FICHA CATALOGRÁFICA

MATTOS, Guilherme Gomes Cardim

Título: A influência de estratégias de marketing adotadas nas vendas de chocolate ao longo da pandemia de COVID-19: estudo de uma empresa multinacional que atua no mercado brasileiro.

120p.: il.; 30cm

Dissertação de Mestrado, apresentada à Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto da Universidade de São Paulo.

Orientadora: Prof.^a Dr.^a Marina Toledo Lourenção Rocha

1.Gestão Estratégica de Marketing. 2.COVID-19. 3.*Machine Learning*. 4. Mercado de chocolate. 5. Gestão de Demanda. 6.Séries Temporais.

AGRADECIMENTOS

Agradeço profundamente à minha companheira Dani, que com sua inteligência admirável me incentivou a não desistir mesmo diante das adversidades. Sempre com as palavras mais lúcidas e precisas para iluminar o caminho por onde passo. Meu alicerce. Meu amor. Minha amiga.

Ao grupo MASPEM, cujos integrantes abrilhantaram minha visão quinzenalmente com críticas e perguntas. Especialmente, Leo e Rafa.

À professora Marina, que me orientou ao longo dessa jornada. Sem sua paciência e grande habilidade para aterrissar as ideias em conteúdos fundamentados essa dissertação não seria possível.

Com sua orientação, meus horizontes expandiram e hoje posso me enxergar como pesquisador. Essa é uma conquista que devo a você. Obrigado.

À minha família cujo apoio incondicional me mostrou que o caminho a ser seguido é aquele que me deixa feliz. Obrigado Mãe, Pai, Nando e Lipe.

Um grande abraço do tio Gui para a Manu, Jojô e Lolô. Vai ser muito legal contar pra vocês daqui uns anos como é fazer um mestrado.

“Andar com fé eu vou, que a fé não costuma faiá”

(Gilberto Gil)

RESUMO

MATTOS, G. G. C. **A influência de estratégias de marketing adotadas nas vendas de chocolate ao longo da pandemia de COVID-19: estudo de uma empresa multinacional que atua no mercado brasileiro.** 2023. (Dissertação de Mestrado) Faculdade de Economia, Administração e Contabilidade de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto.

A pandemia de COVID-19 impôs desafios à gestão estratégica de marketing, este estudo explora o impacto das estratégias de marketing durante a pandemia nas vendas de chocolate de uma empresa multinacional que atua no Brasil, este estudo utiliza de métodos mistos qualitativos e quantitativos bem como técnicas avançadas de *Machine Learning* e interpretabilidade de algoritmos. A aplicação dessas metodologias proporcionou um meio de analisar e interpretar a complexidade e as relações multifatoriais entre investimento em marketing e vendas. Dentre os resultados obtidos com a pesquisa qualitativa destaca-se como as empresas podem se adaptar em contextos de normalidade, grandes mudanças e de crise alterando o foco de suas estratégias de marketing e adaptação de suas estratégias em resposta a mudanças nas condições do mercado. Os resultados quantitativos ofereceram um modelo de previsão de vendas baseado em indicadores econômicos e investimentos em marketing de maio de 2018 a dezembro de 2022, apresentando métricas de MAPE de 6,7% e R^2 0,659. Durante a transição para a pandemia em 2020, período de mudança, a estratégia de Incentivo por Metas contribuiu mais significativamente para as vendas, com 30,06%, enquanto Investimento em Relacionamento com Cliente teve a menor contribuição, com 2,73%. Em 2021, período de crise, a estratégia Investimento em Produto liderou, contribuindo com 35,62%, enquanto o Investimento em Relacionamento com Cliente teve novamente menor contribuição, com 4,30%. Nos anos de normalidade, 2018, 2019 e 2022, Investimento em Produto se manteve como a maior contribuição, contrastando com o Investimento em Publicidade que teve as menores contribuições. Estes resultados destacam a importância de uma gestão estratégica de marketing flexível, capaz de se adaptar a diferentes cenários. A principal contribuição teórica do estudo é a análise da complexa relação entre diferentes estratégias de marketing e as vendas de chocolate, em períodos de normalidade, mudança e crise de modo que se observou que o aumento no investimento em marketing não leva necessariamente a um aumento proporcional nas vendas, além de que indicadores econômicos, como inflação, nível de atividade setorial e taxa de desocupação, podem influenciar significativamente as vendas de chocolates. No aspecto prático, os resultados reforçam a necessidade de adaptabilidade e reorientação de investimentos em tempos de crise, salientando a importância do marketing digital e manutenção de uma oferta constante de produtos. Esta pesquisa indica que a gestão estratégica deve ser ágil e diversificada, capaz de adaptar diferentes estratégias de marketing para maximizar as vendas em variadas condições de mercado.

Palavras-chave: Gestão Estratégica de Marketing; COVID-19; *Machine Learning*; Mercado de chocolate; Gestão de Demanda; Séries temporais

ABSTRACT

MATTOS, G. G. C. **The influence of marketing strategies adopted on chocolate sales throughout the COVID-19 pandemic: a study of a multinational company operating in the Brazilian market.** 2023. (Dissertation) School of Economics, Business Administration and Accounting at Ribeirão Preto, University of São Paulo, Ribeirão Preto.

The COVID-19 pandemic posed challenges to strategic marketing management, and this study explores the impact of marketing strategies during the pandemic on the chocolate sales of a multinational company operating in Brazil. This research employs a mixed approach, incorporating both qualitative and quantitative methods as well as advanced Machine Learning techniques and algorithm interpretability. These methodologies provided a means to analyze and interpret the complex and multifactorial relationships between marketing investment and sales. Qualitative research findings highlighted how companies can adapt in contexts of normality, large-scale changes, and crisis by adjusting their marketing strategies and adapting them in response to changes in market conditions. The quantitative results offered a sales forecasting model based on economic indicators and marketing investments from May 2018 to December 2022, presenting MAPE metrics of 6.7% and R^2 0.659. During the transition to the pandemic in 2020, a period of change, the Goal Incentive strategy contributed most significantly to sales, with 30.06%, while Customer Relationship Investment contributed the least, with 2.73%. In 2021, a period of crisis, the Product Investment strategy led, contributing 35.62%, while Customer Relationship Investment again contributed the least, with 4.30%. In the years of normality, 2018, 2019 and 2022, Product Investment maintained the highest contribution, contrasting with Advertising Investment, which had the lowest contributions. These results highlight the importance of flexible strategic marketing management, capable of adapting to different scenarios. The main theoretical contribution of the study is the analysis of the complex relationship between different marketing strategies and chocolate sales in periods of normality, change and crisis. It was observed that an increase in marketing investment does not necessarily lead to a proportional increase in sales, and that economic indicators, such as inflation, sectoral activity level and unemployment rate, can significantly influence chocolate sales. On a practical level, the results underscore the need for adaptability and reorientation of investments in times of crisis, emphasizing the importance of digital marketing and maintaining a constant product offering. This research indicates that strategic management should be agile and diversified, able to adapt different marketing strategies to maximize sales under varied market conditions.

Keywords: Strategic Marketing Management; COVID-19; Machine Learning; Chocolate Market; Demand Management; Time Series.

LISTA DE TABELAS

Tabela 1 – Resumo dos entrevistados

Tabela 2 – Resumo do modelo de regressão

Tabela 3 – Coeficientes do modelo de regressão: IPCA e atividade econômica

Tabela 4 – Correlação cruzada de Volume de vendas e COVID-19

Tabela 5 – Distribuição da correlação cruzada por semestre

Tabela 6 – Teste de normalidade das variáveis utilizadas

Tabela 7 – Resumo modelo de Machine Learning

Tabela 8 – Assertividade modelo de Machine Learning

Tabela 9 – Efeito normalizado das estratégias na venda de chocolates

LISTA DE FIGURAS

Figura 1 – Modelo de causas e consequências da racionalidade limitada

Figura 2 – Modelo de diferenças entre Sistema 1 e Sistema 2

Figura 3 – Modelo do comportamento do consumidor

Figura 4 – Correlação de Pearson entre variáveis

Figura 5 – Shap Value treino – Valores absolutos

Figura 6 – Shap Value teste – Valores absolutos

LISTA DE GRÁFICOS

Gráfico 1 – Sazonalidade e Tendência de vendas

Gráfico 2 – Sazonalidade trimestral

Gráfico 3 – Tendência trimestral

Gráfico 4 – Variação anual da tendência

Gráfico 5 – Interesse de pesquisa e nº de casos de COVID-19

Gráfico 6 – Série temporal da correlação cruzada

Gráfico 7 – Regressão com Machine Learning

Gráfico 8 – Efeito das estratégias entre anos

Gráfico 9 – Efeito das estratégias relativo ao valor investido (Publicidade)

Gráfico 10 – Efeito das estratégias relativo ao valor investido (Produto)

Gráfico 11 – Efeito das estratégias relativo ao valor investido (Metas)

Gráfico 12 – Efeito das estratégias relativo ao valor investido (Relacionamento)

LISTA DE QUADROS

Quadro 1 – Perguntas aos gestores

Quadro 2 – Relação entre os itens dos procedimentos metodológicos

Quadro 3 – Decisão para hipóteses da dissertação

Quadro 4 – Relação entre objetivos, hipóteses, contribuições teóricas e práticas

Quadro 5 – Framework de resumo dos resultados

Sumário

1. INTRODUÇÃO	16
1.1. Problema de pesquisa	21
1.2. Objetivos	21
2. REFERENCIAL TEÓRICO	23
2.1. Economia comportamental	23
2.2. Comportamento do consumidor	27
2.2.1. Teoria da atitude	29
2.3. Gestão das estratégias do composto de marketing (4Ps)	31
2.3.1. Gestão de produto	31
2.3.1.1. Design do produto	32
2.3.1.2. Manufatura do produto	32
2.3.1.3. Operação do produto	33
2.3.2. Gestão de preço	33
2.3.3. Gestão da promoção	34
2.3.4. Gestão da praça	35
2.4. COVID-19 no Brasil e no Mundo	36
2.5. Gestão da demanda	37
2.6. Inteligência artificial e Machine Learning	38
2.6.1. Interpretabilidade de modelos de inteligência artificial e Machine Learning	40
2.7. Construção de hipóteses	41
2.7.1. Hipóteses	42
3. MÉTODO	46
3.1. Método para 1ª etapa: estudo qualitativo	46
3.1.1. Tipo de pesquisa	46
3.1.2. Coleta de dados	46
3.1.3. Análise dos dados qualitativos	48
3.2. Método para 2ª etapa: estudo quantitativo	48
3.2.1. Tipo de pesquisa	48
3.2.2. Coleta de dados	49
3.2.3. Análise dos dados quantitativos	50
4. RESULTADOS E DISCUSSÃO	58
4.1. Objetivo específico I: apresentação das estratégias de marketing utilizadas pela empresa	58
4.1.1. Investimento em publicidade	58
4.1.2. Investimento em visibilidade de produto	59
4.1.3. Incentivo por meio de metas	60
4.1.4. Relacionamento com cliente	61
4.2. Objetivo específico II: análise das mudanças que ocorreram nas vendas de chocolates ao longo do período pandemia da COVID-19	61
4.3. Objetivo específico III: análise da influência da percepção de risco da pandemia da	

COVID-19 nas vendas chocolates no período	64
4.4. Objetivo Geral: efeito das estratégias de marketing adotadas ao longo da pandemia da COVID-19 nas vendas de chocolate	69
4.4.1. Verificação de multicolinearidade	71
4.4.2. Especificação do modelo	72
4.4.3. Resultados do modelo	73
4.4.4. Interpretabilidade do impacto das variáveis independentes nas vendas de chocolates	75
5. CONCLUSÃO	89
5.1. Conclusões finais da dissertação	89
5.2. Limitações do estudo e sugestão de estudos futuros	97

1. INTRODUÇÃO

O comportamento do consumidor é um campo de pesquisa que se aprofunda sob diversas óticas; no campo da economia, desdobra-se na perspectiva clássica que parte do princípio de que o indivíduo toma decisões racionais diante de uma hierarquização de preferências e satisfação (JACOB, 2000), agindo de forma a maximizar a utilidade esperada (ALLEN, 2004). Na economia comportamental, em intersecção com a Psicologia, parte-se do exame das influências cognitivas, sociais e emocionais acerca da conduta econômica das pessoas (SAMSON, 2015; MCCARTHY et al 2020), pressupondo limites para a racionalidade assim como padrões de vieses sistemáticos que influem na tomada de decisão (ARIELY, 2008; KAHNEMAN, 2011). Tendo-se também contribuição no campo da administração e marketing, desde a hierarquia de necessidades de Maslow (ROJAS et al, 2023), à análise de como os indivíduos, grupos e organizações compram, usam e descartam bens e serviços para satisfazer desejos e necessidades (SOLOMON, 2011), sob a influência de fatores culturais, sociais e pessoais (KOTLER, 2012).

Segundo Hawkins (2010), a estratégia de marketing se baseia na influência do desejo do consumidor, que para se atingir esse objetivo deve-se conhecer os fatores que afetam seu comportamento. Neste sentido, a compreensão do comportamento do consumidor, não apenas contribui para o êxito mercadológico, mas tem o potencial de desenvolver melhores consumidores, melhores profissionais de marketing e melhores cidadãos (HAWKINS 2010). Kotler & Keller (2012), por sua vez, sustenta que a compreensão sobre as necessidades, preferências e o comportamento do consumidor contribui para o diagnóstico sobre “como” e “por que” incidem-se determinadas tendências de mercado, que podem ser compreendidas como forças, fraquezas ou oportunidades.

Para compreender o ambiente de marketing e subsidiar a tomada de decisão empresarial, faz-se necessário ter-se uma compreensão contemporânea do consumidor, que é agente do comportamento. Sua forma de expressão de consumo é frequentemente complexa, desorganizada, inconsciente, orgânica e circular (HAWKINS, 2010). De acordo com Ferguson (1996), trata-se de um indivíduo que expressa a si mesmo por meio de suas posses e cuja expressão da sua individualidade se dá na forma de consumo. Como resultado de uma construção social que se inicia a partir do século XVII, e culmina numa nova era do sujeito (DARDOT & LAVAL 2016). Era esta, que Bauman (2001, p. 96-99) descreve como a

substituição da necessidade pelo desejo no processo de tomada de decisão de consumo, “entidade muito mais volátil, efêmera, evasiva e caprichosa”. Embora as necessidades sejam muito menos maleáveis e lentas que o desejo, este requer considerável esforço para se despertar e canalizar. De tal modo que para se manter a demanda do consumidor no nível da oferta crescente, deve-se produzir novos consumidores atraídos pelo desejo de adquirir novos bens e habilidades cada vez mais estimulantes e versáteis, com os indivíduos expressando sua individualidade através do consumo (FERGUSON, 1996; BAUMAN, 2001; DARDOT, 2016).

À medida que evoluímos para um consumidor impulsionado mais por desejos do que por necessidades, torna-se cada vez mais importante adaptar nossas estratégias para manter a demanda do consumidor em sintonia com a oferta crescente. Neste sentido, após entender o comportamento do consumidor, as empresas criam estratégias de marketing adequadas ao seu comportamento, tais como o composto de marketing. Esta ferramenta é usada por décadas no contexto empresarial (LONDHE, 2014), originando-se com McCarthy (1964) que propôs o "mix de marketing", muitas vezes referido como "4Ps", como um meio de traduzir o planejamento de marketing em prática. Que se consolidou como composto de marketing, uma parte integral da estratégia de marketing de uma empresa, situando-se no ponto de encontro entre a empresa e o mercado (WICHMANN et al 2022). Como tal, ele evoluiu junto com o mercado e seus stakeholders até uma dimensão de "7Ps" do inglês *Product, Price, Promotion, Place, People, Physical evidence and Process on Purchasing* (ASTUTI et al 2015; KWOK et al 2020).

Para monitorar a efetividade das estratégias de marketing, a gestão de demanda se torna uma das atividades críticas da gestão da operação de supply chain (CRUM & PALMATIER, 2003). O gerenciamento de demanda apoia decisões gerenciais e planejamento operacional ao longo da cadeia de suprimentos (BANDEIRA et al., 2020). Desta forma, para o processo de Planejamento de Vendas e Operações (S&OP), a gestão da demanda é essencial para tomada de decisão (SEELING et al., 2019). A maioria das empresas realiza a gestão da demanda utilizando apenas variáveis de venda no tempo, criando modelos de séries temporais univariados (ARBOLEDA-FLOREZ & CASTRO-ZULUAGA, 2023). Entretanto, modelos com cada vez mais variáveis e técnicas baseadas em aprendizado de máquina são utilizados para resolver problemas complexos. Estas ferramentas se tornam progressivamente mais valiosas para encontrar e aprender padrões nos dados. Elas possibilitam fazer previsões,

descobrir estruturas ocultas e encontrar relações significativas entre os dados (MIRJALILI, et. al 2019).

No entanto, uma grande parte desses modelos de aprendizado de máquina são classificados como "caixas-pretas" devido à sua elevada complexidade e baixa capacidade de interpretação, tornando desafiador desenvolver um entendimento completo e garantir a confiança em suas previsões (AMIRI et al., 2021). A utilização desses modelos cria um conflito entre a precisão das previsões e a interpretabilidade dos resultados. Em contextos de tomada de decisões estratégicas, onde se utilizam métodos preditivos, a compreensão das razões que embasam uma determinada previsão pode ser tão vital quanto a precisão dessa previsão em diversas aplicações (LUNDBERG; LEE, 2017).

Nesse cenário, é apresentada a Inteligência Artificial Explicável [IAE], conforme discutido por Barredo Arrieta et al. (2020, p. 83), propõe a criação de uma série de técnicas de Aprendizado de Máquina que produzem modelos mais explicáveis, enquanto mantêm um alto nível de desempenho (por exemplo, precisão de previsão), e permite que os humanos entendam, confiem adequadamente e gerenciem efetivamente a nova geração de parceiros de inteligência artificial. Dado o exposto, torna-se essencial integrar as técnicas avançadas de aprendizado de máquina e Inteligência Artificial Explicável (BARREDO ARRIETA et al., 2020) ao estudo do comportamento do consumidor. Compreender as motivações, necessidades e mudanças no comportamento de compra, aliado à utilização de modelos de previsão que garantem alta precisão e interpretabilidade, pode oferecer um entendimento mais completo e confiável para apoiar a tomada de decisões estratégicas.

Essa integração da IAE ganha ainda mais relevância considerando os impactos substanciais da pandemia na indústria de chocolates, desde a produção até a comercialização (CADBY, 2021). Em um cenário em que o mercado busca práticas sustentáveis e éticas, a capacidade de compreender as mudanças no comportamento do consumidor e adaptar as estratégias de marketing de forma eficaz torna-se essencial para enfrentar desafios semelhantes no futuro. Portanto, explorar a aplicação da IAE como uma ferramenta poderosa para analisar e prever o comportamento do consumidor no mercado de chocolates no Brasil pode fornecer insights valiosos para a formulação de estratégias que ajudem a impulsionar a recuperação e a prosperidade desse setor em situações de crise global, como a vivenciada durante a pandemia.

O mercado de chocolates no Brasil enfrenta desafios significativos, especialmente à luz dos recentes acontecimentos. Ao considerar a situação em contexto global, o mercado europeu de chocolate foi avaliado em US\$ 44.762,65 milhões em 2022, de acordo com a Mordor Intelligence (2023). Em contraste com os impressionantes valores Brasileiros desse mercado, que apenas em exportações de 2021 totalizou 35,8 mil toneladas, com um valor de US\$ 141,3 milhões a Associação Brasileira da Indústria de Chocolates, Cacau, Amendoim, Balas e Derivados [ABICAD], além das 693 mil toneladas de chocolates produzidos em 2021 (ABICAD, 2022). Essa disparidade destaca a oportunidade de crescimento e expansão do mercado brasileiro, especialmente considerando as expectativas da Associação Nacional da Indústria de Processamento de Cacau [AIPC] de dobrar a produção de matéria-prima para chocolate até 2028, alcançando 400.000 toneladas métricas por ano (Mordor Intelligence, 2023). Além disso, no cenário sul-americano, onde o Brasil desempenha um papel fundamental como um dos maiores produtores de cacau, empresas como Nestlé, Lindt & Sprüngli AG, The Hershey Company, Ferrero Group, Mondelēz International e Grupo Arcor são os principais atores do mercado de chocolates (MORDOR INTELLIGENCE, 2023)

No contexto nacional, a ABICAD desempenha um papel crucial, representando 92% do mercado de chocolates no Brasil e contribuindo para a geração de cerca de 23 mil empregos diretos. Além disso, o Brasil mantém uma posição notável entre os cinco principais países em volume de vendas de chocolate no varejo, atrás apenas dos Estados Unidos, Alemanha, Rússia e Reino Unido (ABICAD, 2022, *apud* Euromonitor). No ano de 2022, o setor de chocolates no Brasil registrou um volume de produção de 760 mil toneladas, representando um crescimento de 8,3% em relação ao mesmo período de 2021.

Em meio a esse cenário dinâmico, a pandemia de COVID-19, assim como a implementação de medidas de contenção sanitária, suscitou proibições de viagens, isolamento social, quarentena comunitária e fechamento de escolas a partir de 2020 (ZHOU, 2021). Implicando-se também impactos de âmbito social, cultural, econômico e psicológico (BUKULUKI et al., 2021), fatores estes que podem perdurar influenciando decisões de compra e a estrutura de mercado pós-pandemia (KIM, 2020; YAN et al., 2020; SHETH, 2020). Podendo-se até criar hábitos e comportamentos de consumo de efeito duradouro (SOARES et al., 2022). Desde o início da crise de saúde pública, ocorreram fenômenos sociais como fomento de compras motivadas por pânico que causaram impactos na cadeia de suprimentos de gêneros alimentícios (CHENARIDES et al., 2020), haja visto que a oferta de

produtos é suscetível às mudanças abruptas na demanda, como compra de pânico e estocagem (UPTON & NUTTALL, 2014). Observou-se também o agravamento de quadros de ansiedade (KNOWLES et al., 2021; SERAFINI et al., 2020) diante do risco percebido de contrair COVID-19 (SOARES et al., 2022). Assim como a elevação no consumo de álcool como resultado do aumento do nível de estresse e redução da interação social (SZAJNOGA et al., 2020). Que também promoveu um maior investimento de tempo em atividades digitais (KEMP, 2020), assim como crescimento de compras realizadas em ambientes online (KIM, 2020). Além da súbita mudança no padrão de compra de refeições motivado pelo pânico com o aparecimento da COVID-19, que causou choques de demanda e levou à escassez de mão de obra e interrupções na rede de transporte e distribuição (HOBBS, 2020), no contexto em que a pandemia levou a um padrão de demanda intermitente (NIKOLOPOULOS, 2020).

Diversos estudos apontaram que a segunda década do século 21 se iniciou com drástico declínio de renda, gerando o decaimento da diversidade da cesta de consumo como exemplo do Estados Unidos (BAKER et al., 2020), Reino Unido (HACIOGLU et al., 2020), Suécia e Dinamarca (SHERIDAN et al., 2020). Os efeitos da pandemia se distribuíram de maneira desproporcional variando de acordo com o contexto socioeconômico e o setor de mercado analisado (KUBOTA et al., 2021). Indivíduos com maiores níveis de educação, renda e que estão em ocupações de maior prestígio social, têm mais recursos para lidar com a doença, portanto, estão menos preocupados com os efeitos da pandemia (ZHOU et al., 2021). No contexto brasileiro, os estudos sobre as mudanças comportamentais suscitadas pela pandemia envolvem análises sobre alterações de estilo de vida como: tempo em frente a telas, consumo de bebidas alcoólicas e cigarros (MALTA et al., 2020). Além disso, há evidências sobre mudanças acerca do consumo com consciência ambiental e sustentável, assim como adoção de ações de responsabilidade social nesse contexto (SEVERO et al., 2020). As empresas tiveram que elaborar novas estratégias de marketing para se adaptar a este novo contexto.

Dessa forma, a presente dissertação propõe explorar a influência das estratégias de marketing na venda de chocolates durante a pandemia de COVID-19, por meio do estudo de uma empresa multinacional que atua no mercado brasileiro. Este trabalho irá recorrer ao uso de técnicas estatísticas, inteligência artificial e estratégias de Inteligência Artificial Explicável, permitindo assim a geração de previsões precisas e interpretáveis. O presente estudo pretende trazer contribuições valiosas para a compreensão do comportamento do

consumidor e a eficácia das estratégias de marketing em tempos de crise global, oferecendo insights valiosos para acadêmicos e profissionais da área de marketing.

1.1. Problema de pesquisa

Ao considerar que a pandemia acarretou mudanças consideráveis em nossa sociedade em âmbito econômico, cognitivo, afetivo e comportamental bem como essa condição influenciou a decisão de consumo dos indivíduos e requereu adaptação estratégica das empresas esse estudo busca responder ao seguinte **problema de pesquisa**: qual é o impacto das estratégias de marketing adotadas por uma empresa que atua no mercado brasileiro nas vendas de chocolates ao longo da pandemia da COVID-19?

1.2. Objetivos

O objetivo geral da pesquisa é avaliar o efeito que as estratégias de marketing adotadas ao longo da pandemia da Covid-19 nas vendas de chocolate de uma empresa que atua no mercado brasileiro. Dentre os objetivos específicos, estão:

- Objetivo específico I: Identificar quais foram as estratégias de marketing utilizadas pela empresa estudada no mercado de Chocolates ao longo da crise de COVID-19.
- Objetivo específico II: Verificar quais mudanças que ocorreram nas vendas de chocolates ao longo da pandemia da COVID-19
- Objetivo específico III: Verificar como a percepção de risco da pandemia da COVID-19 afetou as vendas chocolates no período analisado

A decisão de estudo sobre o mercado de chocolates nesta dissertação advém de vários fatores. Primeiramente, a abrangência e diversidade dos consumidores neste segmento permite um estudo amplo sobre comportamentos de consumo. Especificamente, Além disso, o pesquisador possui uma inserção direta no contexto real da empresa estudada, o que proporciona um entendimento íntimo dos desafios e estratégias adotadas. Esta perspectiva interna contribui de maneira significativa para a validade e relevância dos resultados da pesquisa. Embora pesquisas prévias tenham analisado o impacto da pandemia no comportamento do consumidor (ANDRADE-MATOS et al., 2022; CADBY, 2021), esta dissertação tem a intenção de ir além, avaliando o efeito de estratégias de marketing específicas no mercado de chocolates.

Ademais, o presente estudo visa contribuir para tomada de decisão competitiva do mercado privado e fundamentar estratégias de marketing, além de aprofundar a compreensão teórica sobre os impactos e reflexos da pandemia no comportamento do consumidor e decisão estratégica de marketing na dinâmica do mercado haja visto que há pesquisadores que mostram a relevância e a necessidade de aprofundamento acadêmico do tema (KIM, 2020; JO et al., 2020). Addo et al. (2020) evidencia a necessidade de se entender a tendência e os impactos da pandemia do COVID-19 no comportamento de compra do consumidor, assim como expandir a compreensão do efeito do COVID-19 nos consumidores e nas culturas de consumo (KIM, 2020).

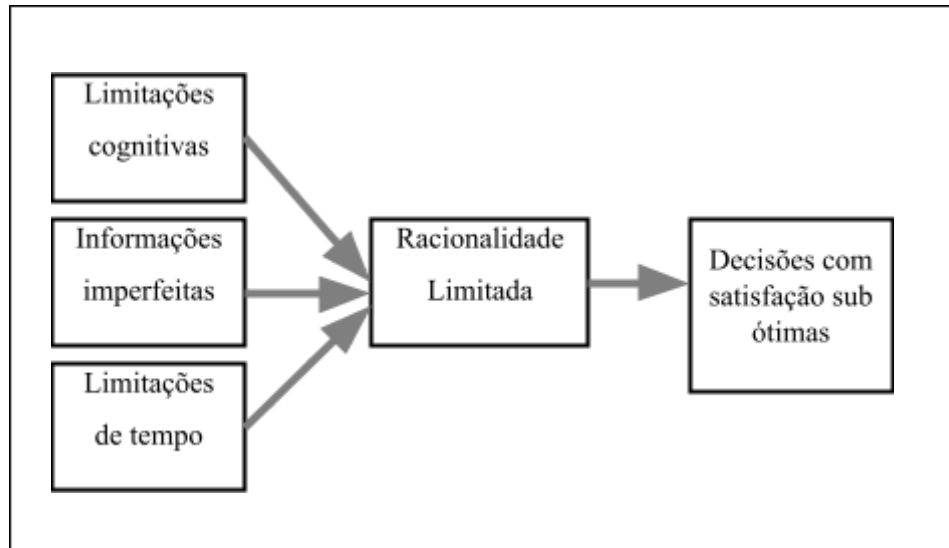
2. REFERENCIAL TEÓRICO

2.1. Economia comportamental

Desde o século XVIII, o pensamento econômico se fundamenta em princípios acerca da tomada de decisão racional dos indivíduos (SENT, 2018). No entanto, a interpretação sobre a racionalidade mudou ao longo do tempo (SENT, 2008). Sendo assim, inicialmente ela era associada a um conjunto de leis naturais (DASTON, 1987), motivadas pelo auto interesse (ELSTER 1989). A partir do século XX, as áreas de estudo de tomada de decisão foram fundamentadas em escolha racional e utilidade esperada (JACOB, 2000). Concebendo-se a utilidade como aquilo que se pretende maximizar ao fazer escolhas, sendo um conceito que se associa à satisfação obtida ao se adquirir algo (JUSTER, 1990), neste sentido, a perspectiva tradicional acerca da teoria da utilidade esperada parte da premissa que os indivíduos detêm informações completas sobre cada produto, bens ou serviços e avaliam essas informações de maneira deliberada para escolher aquele que apresenta a maior utilidade. Ademais, o indivíduo é sujeito às restrições de orçamento e disponibilidade (ALLEN, 2004).

Segundo Friedman (1953), as preferências individuais não são observáveis ou plenamente conhecidas, indicando que os indivíduos podem realmente não estar cientes dos processos mentais envolvidos na tomada de decisão, pois parte considerável desses processos se dão num contexto tácito, em oposição à plena racionalidade. Posteriormente Simon, (1957) elaborou a expressão “racionalidade limitada”, que parte da premissa que para os atores econômicos serem capazes de maximizar a utilidade, devem ser agentes racionais perfeitos. Para Selten (1999) a concepção de que os agentes econômicos são dotados de capacidade de tomar decisões que maximizem utilidades subjetivas com bases estritamente racionais construíram uma teoria irrealista acerca da tomada de decisão humana. Campitelli & Gobet, (2010) resumem a abordagem de Simon para a tomada de decisões essencialmente em três premissas principais: primeiro, as decisões não são realizadas por agentes com perfeita racionalidade, pois são tomadas por agentes com racionalidade limitada; segundo, a qualidade das decisões varia em função da expertise do tomador de decisão; terceiro, para entender a tomada de decisões, é primordial investigar os processos cognitivos envolvidos.

Figura 1 - Modelo de causas e consequências da racionalidade limitada



FONTE: adaptado de Simon, 1956 e Send, 2018

Em condições de racionalidade limitada, Send (2018) ressalta circunstâncias que os indivíduos se deparam com habilidades restritas para resolução de problemas e tomada de decisão. Por exemplo, em contextos de tomada de decisão sob risco, em que a aversão à perda pode superar o desejo por ganhos; ou quando pessoas perseguem objetivos relativos aos outros, como justiça, altruísmo recíproco e vingança, em que se pode levar a escolhas que não são do seu interesse a longo prazo. Send (2018) indica ainda que os seres humanos muitas vezes estão dispostos a sacrificar seus próprios interesses para ajudar os outros, além de os indivíduos por vezes interpretarem erroneamente as evidências que estão em conformidade com suas hipóteses. Para Tversky (1977), julgamentos subjetivos geralmente não obedecem aos princípios normativos básicos da teoria da decisão. Sendo a tomada de decisão sujeita a processos cognitivos subjacentes à formação de preferência e crença. Pois os julgamentos humanos parecem seguir certos princípios que conduzem a respostas razoáveis e por vezes a erros sistemáticos. Além disso, as premissas da escolha racional são frequentemente violadas de maneira sistemática e indiferente ao nível de escolaridade do indivíduo avaliado (TVERSKY & KAHNEMAN, 1974; KAHNEMAN & TVERSKY, 1979).

Ao longo do século XX, psicólogos aprofundaram seus estudos sobre o processo de tomada de decisão e as distintas formas de pensamento que o fundamentam. Tais processos

cognitivos foram agrupados e nomeados originalmente por Stanovich & West (2000, p.658) de “Sistema 1”, que opera de forma automática e majoritariamente inconsciente e cujo objetivo é a capacidade de compreender a intenção externa percebida e responder com movimentos interacionais rápidos. Enquanto o “Sistema 2” contempla diversas características típicas do processamento controlado, que requer atenção e esforço mental. Conceitualizando que a diferença mais importante entre ambos os sistemas é que eles tendem a levar a diferentes tipos de interpretações de tarefas, enquanto as construções decorrentes do Sistema 1 se apresentam de forma contextualizada, personalizada e socializada. Sendo a diferença mais importante entre os dois sistemas é que eles tendem a levar a diferentes tipos de interpretações de tarefas. Dado que as construções desencadeadas pelo sistema 1 são altamente contextualizadas, personalizadas e socializadas e conduz a uma tendência de contextualização automática de problemas (STANOVICH 1999) que foi nomeada por Levinson (1995) como inteligência interacional. Em oposição, o sistema 2 tem como finalidade descontextualizar e lidar com problemas em termos de regras e princípios sendo descrito como inteligência analítica (STANOVICH & WEST 2000).

Kahneman, (2011) descreve o sistema 1 como fonte de impressões e sentimentos que expressa sem esforço as crenças e escolhas deliberadas do sistema 2, que ao assumir o controle, anula os impulsos e associações livres do sistema 1 em circunstâncias onde a tomada de decisão em menor velocidade é possível. No contexto da tomada de decisão de compra no varejo físico, Kardes et. al. (1992) analisa a tendência de escolha por um pequeno número de marcas para consideração quando consumidores passam por uma gôndola de supermercado, pois nesse contexto se tem apenas uma quantidade pequena de tempo para efetivar uma escolha. Sendo mais provável que o conjunto de marcas seja o das mais vívidas na memória. Dentre as marcas vívidas, Carpenter, et. al (2006, 77-78) denota que se destacam as pioneiras, pois estas se apropriam de uma participação do mercado enquanto há uma assimetria de informação dos consumidores, num contexto em que se estabelece uma comparação viável que organiza a competição com novos entrantes. Destacam-se também aquelas que estabelecem padrões tecnológicos, como o teclado QWERTY da Microsoft e padrões psicológicos como Cadillac que representou a referência de luxo e Volkswagen o conceito de carro econômico.

Nem sempre os compradores consideram todas as opções, ponderam-nas cuidadosamente e chegam a uma escolha deliberada no sentido convencional da

racionalidade (KAHNEMAN et. al, 1979). Assim como, nem sempre os compradores sabem o que desejam, pois os indivíduos aprendem o que gostam e aprendem como escolher, configurando-se um processo de aprendizagem que dura toda a vida (CARPENTER, et. al 2006). Concebendo-se com isso graus de incerteza e risco associados à tomada de decisão individual (KAHNEMAN, 2011), sendo que Slovic, (2000) conceitua o risco como uma elaboração intelectual para ajudar os humanos a entender e lidar com os perigos e incertezas da vida. Conceito esse que não está desassociado das mentes e cultura das pessoas nem existe em uma natureza mensurável diante de perigos reais.

Para circunstâncias de tomada de decisão sob risco, Kahneman (2011) apresenta o conceito de heurística do afeto (*affect heuristic*) em que os indivíduos permitem que suas simpatias e antipatias influenciem o julgamento sobre argumentos e conclusões sobre quão convincentes de fato são. Por exemplo, a preferência política individual podendo determinar os argumentos que se julgam convincentes, determinando-se com isso o viés comportamental sistemático denominado “viés de disponibilidade”. Exemplificado por Kahneman, (2011), na atitude de californianos que apresentam maior suscetibilidade a adquirir seguros e adotar ações de proteção imediatamente após cada terremoto, mas à medida que a lembrança do desastre esmaece enfraquece-se também as preocupações e ações cautelares. Além disso, a existência de informações sobre riscos menores para uma determinada ação também altera a perspectiva sobre benefícios positivos potenciais da mesma, ainda que não se tenha informação objetiva alguma sobre alteração dos benefícios (FINUCANE, 2000).

Figura 2 – Modelo de diferenças entre Sistema 1 e Sistema 2

	Percepção	Intuição Sistema 1	Raciocínio Sistema 2
Processo	Rápido Paralelo Automático Sem esforço Associativo Aprendizado em baixa velocidade		Devagar Serial Controlado Demanda esforço Flexível
Conteúdo	Dependente de: percepção Estímulo Limites da percepção do estímulo	Representação conceitual Passado, presente e futuro Pode ser expresso pela linguagem	

FONTE: Adaptado de Egidi, 2005. p. 16

Embora o Sistema 2 se caracterize na forma de busca ativa e deliberada de memória, em cálculos complexos, comparações, planejamento e escolha, apresentando-se também com a capacidade de resistir às sugestões do Sistema 1. No contexto das atitudes, “o Sistema 2 age mais como um defensor para as emoções do Sistema 1 do que como um crítico dessas emoções - ele mais endossa que impõe”. Denotando-se que a procura por informações e argumentos está restrita à obrigatoriedade de estar consistente com crenças existentes, não com uma intenção de examiná-las, o que revela a complacência do sistema 2 na legitimação racional dos sentimentos que emergem do sistema 1 (KAHNEMAN, 2011, 103-104). Dada a circunstância da COVID-19, assim como risco percebido da pandemia, compreender o impacto do viés da disponibilidade no consumo dos indivíduos apresenta elevada importância, assim como evidenciar o enfraquecimento desse efeito à medida que a pandemia também reduz a sua periculosidade.

A economia comportamental é um dos pilares teóricos que fundamenta a tomada de decisão em Marketing e consiste em um dos métodos utilizados para compreensão do comportamento do consumidor, assunto abordado no próximo tópico.

2.2. Comportamento do consumidor

O estudo do comportamento do consumidor envolve a compreensão sobre como os indivíduos utilizam bens e serviços para satisfazer necessidades e desejos (SOLOMON, 2011). Para Hawkins (2011), o comportamento do consumidor contempla um processo complexo e multidimensional que se dá em etapas, sendo influenciado por fatores culturais, sociais e pessoais. No campo da administração de processos de marketing Kotler, (2012) descreve os aspectos de influência do comportamento em:

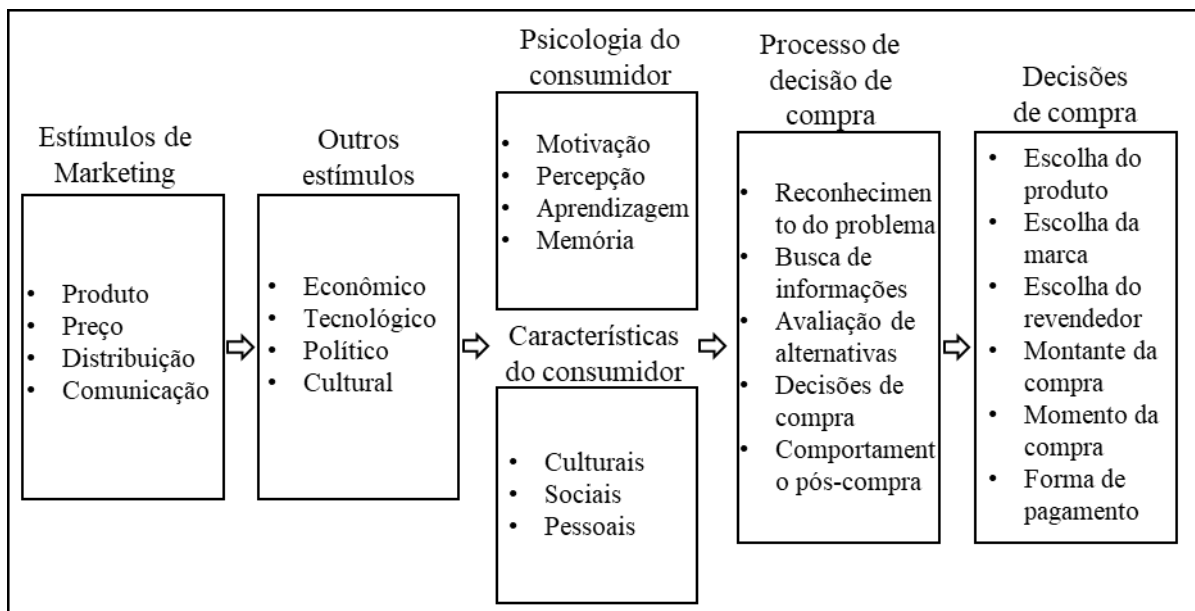
- **Fatores Culturais:** trata-se da consideração de valores culturais típicos de um determinado país de forma a identificar oportunidades de desenvolvimento de ofertas que estejam alinhadas com as necessidades de mercado locais. Sendo que cada cultura é composta por subculturas que promovem identificação e socialização mais específicas de seus membros, e podem ser discriminadas em termos mais granulares como nacionalidades, as religiões, os grupos raciais e as regiões geográficas. Podendo-se compreender os fatores culturais em termos de classes sociais, que se apresentam em divisões relativamente homogêneas e duradouras numa sociedade, com ordenação hierárquica e cujos integrantes possuem potencialmente valores, interesses e comportamentos similares.
- **Fatores Sociais:** considera-se aqui fatores que exercem alguma influência direta ou indireta sobre as atitudes ou o comportamento de uma pessoa e partem de grupos de afinidade que expõem os indivíduos a novos comportamentos e estilos de vida, e tem o potencial de influenciar atitudes e autoimagem além de fomentar a necessidade por aceitação social que pode afetar as escolhas reais de produto e marca. Sendo os grupos primários, a família, amigos, vizinhos e colegas de trabalho, com os quais se interage de modo contínuo e informal. Enquanto os grupos secundários, religiosos, profissionais ou associações de classe, que costumam ser mais formais e exigir menos interação contínua. Grupos aos quais não se pertence também podem ter o potencial de influenciar a tomada de decisão individual, como o caso dos grupos aspiracionais que são aqueles aos quais se espera pertencer e que se expressam de acordo com o papel social determinado. Os papéis implicam num conjunto de atividades que se espera que uma pessoa desempenhe, sendo que cada papel implica em um

determinado status. As pessoas escolhem produtos que comunicam seu papel e seu status, real ou desejado, na sociedade.

- Fatores Pessoais: contempla-se neste tópico as características pessoais, como idade e estágio no ciclo de vida, ocupação, personalidade e autoimagem, estilo de vida e valores que influenciam gostos e preferências. No que compete ao estágio do ciclo de vida, ocupação, personalidade e autoimagem, estilo de vida e valores que influenciam gostos e preferências. No que compete ao estágio do ciclo de vida do consumidor, há situações típicas pelas quais se passa ao longo da vida, como casamento, nascimento do filho, saída dos filhos de casa, que implicam em transformações das necessidades e preferências.

Os fatores de influência no comportamento do consumidor podem ser compreendidos através de um modelo de estímulo e resposta, em que os estímulos ambientais e de marketing adentram o consciente do comprador e interagem com um conjunto de fatores psicológicos. Quando associado a determinadas características do consumidor leva a processos de decisão e decisões de compra (KOTLER 2012). Como pode ser compreendido através da Figura 3.

Figura 3 – Modelo do comportamento do consumidor



FONTE: Adaptado de Kotler, 2012, p. 172

Rajagopal (2019) corrobora com Kotler (2012) e define que fatores externos como economia de mercado, cultura, valores sociais, moda e políticas corporativas influenciam

amplamente as percepções, atitudes e comportamento do consumidor. Para Kamakura & Du (2012), o contexto econômico, em termos de contrações ou expansões ou até alterações na relação entre renda e despesa dos consumidores podem também afetar o orçamento de consumo, assim como causar ajustes nos padrões de gastos. A análise das dimensões demográficas e culturais apresenta uma medida determinante do grau de impacto da economia no comportamento de consumo dos indivíduos, pois os consumidores tomam decisões de compra de forma a otimizar vantagens comparativas sobre as marcas. Além do contexto econômico, a forma de pagamento também pode alterar a dinâmica de consumo dos indivíduos, como a disponibilidade de meios físicos de pagamento em espécie, uso de cartões de crédito e débito e limites de crédito para realizar compras (COBLA & ASSIBEY, 2018). Também a conveniência de gastar usando serviços de dinheiro móvel tem uma influência significativa na construção do comportamento do consumidor (KAMAKURA & DU, 2012).

A tomada de decisão dos consumidores também pode ser compreendida por meio da teoria da atitude que é abordada no próximo tópico.

2.2.1. Teoria da atitude

Segundo Van Harreveld (2015), a teoria da atitude contempla um campo de estudo que envolve a capacidade de realizar avaliações, sendo que o processo avaliativo tende a ocorrer de forma rápida e sem exigir muito esforço cognitivo. Haja visto que as avaliações estão baseadas num conjunto relativamente estável de associações que juntas formam uma atitude (CUNNINGHAM et. al, 2007). No campo de administração e Marketing, a teoria da atitude contempla a tendência de avaliar um determinado objeto segundo um grau de desfavor ou favor baseando-se em reações emocionais, comportamentais e avaliações cognitivas (EAGLY & CHAIKEN, 1993), componentes estes que são operacionalizados por Roth & Diamantopoulos, (2009) e Asiegbu et. al. (2012) em três elementos: cognitivo, afetivo e conativo/comportamental. Classificado por Chou et. al (2020) em inglês *C-A-B models (Cognitive, Affective Behavioral or Conative components)*.

- Componente Cognitivo: refere-se ao conhecimento, crenças e opiniões do indivíduo (EAGLY & CHAIKEN, 1993) e reflete a informação e o conhecimento do sobre um objeto ou conceito de modo a influenciar uma avaliação (ASIEGBU et. al 2012). Para Netzer et. al (2018), o componente cognitivo interage com as emoções segundo a

interpretação entre o quão útil ou prejudicial uma emoção é, trazendo um componente de avaliação utilitária sobre o comportamento.

- **Componente Afetivo:** é referente aos sentimentos de ordem positiva ou negativa que emergem diante da avaliação de emoções em relação ao objeto da atitude. A resposta afetiva é relacionada ao conteúdo emocional, de modo a despertar gostos ou desgostos de um determinado objeto (EAGLY & CHAIKEN, 1993; NETZER, et. Al 2018). O componente afetivo da atitude pode estar associado aos julgamentos hedônicos, que se associam com aspectos da percepção de prazer (CHOU et. al 2020). Harmon-Jones et al. (2011) concentrou-se na avaliação das atitudes diante de emoções e introduziu a escala de atitudes em relação à emoção (ATE, da sigla em inglês para *Attitudes toward Emotion*), que mede as atitudes das pessoas em relação a cinco emoções distintas (alegria, tristeza, raiva, medo e nojo). Em uma série de estudos, eles mostraram que atitudes mais positivas (ou mais negativas) em relação a uma emoção estavam relacionadas a tentativas de aumentar (ou diminuir) as experiências dessa emoção. Por exemplo, indivíduos com atitudes mais negativas em relação ao medo foram mais motivados a evitar estímulos de medo depois de assistir a um clipe de filme indutor de medo (HARMON-JONES et. al, 2011; NETZER et. al, 2018).
- **Componente Comportamental/Conativo:** trata-se da expressão de tendências comportamentais de tentativa de ação em relação ao objeto de atitude. Ele contempla a probabilidade ou tendência de um indivíduo realizar uma ação específica ou se comportar de uma maneira particular em relação a um objeto da atitude (EAGLY & CHAIKEN, 1993). Para Asiegbu et. al (2012), o componente conativo é frequentemente tratado como uma expressão da intenção de compra do consumidor, em que se avalia a probabilidade de um consumidor comprar um produto ou se comportar de uma determinada maneira. Podendo-se atribuir escalas de intenção de comportamento, que incluem intenção de compra, intenção de atendimento, intenção de compra, intenção de uso, disposição de indicar outras pessoas, dentre outras (ASIEGBU et. al 2012). Geralmente, as escalas de intenção de comportamento são boas preditores das escolhas dos consumidores de produtos de consumo duráveis e comprados com frequência. (SICILIANO, 1993).

2.3. Gestão das estratégias do composto de marketing (4Ps)

Segundo Kramoliš & Kopečková (2013), a gestão do composto de marketing é particularmente importante na criação de vantagem competitiva, pois determina como a empresa competirá diante dos seus mercados-alvo. Lahtinen et al., (2020) e Rahmani et al., (2015) corroboram que a utilização do composto de Marketing, também conhecido como 4P (Produto, Preço, Praça, Promoção), é uma estratégia aplicável tanto em negócios de grande quanto de pequena escala para aumentar as vendas.

Assim, a fim de entender a fundo a aplicabilidade e eficácia desta estratégia, é essencial detalhar cada componente do composto de marketing nas seções a seguir.

2.3.1. Gestão de produto

Segundo Wang et. al (2021) a década de 1980 marcou o início da implementação progressiva do Gerenciamento do Ciclo de Vida do Produto (do inglês *Product Lifecycle Management* - PLM) no campo da engenharia de manufatura, que resultou em uma nova divisão de processos de PLM que abrange desde a análise de mercado e design do produto, até o desenvolvimento de processos, manufatura, distribuição, uso, serviço pós-venda e reciclagem. Desde então o PLM transformou-se em uma infraestrutura de informações crítica, onde fabricantes podem integrar continuamente tecnologias e aplicações emergentes que envolvem a aquisição e processamento de informações do produto, gerenciamento de preferências e comportamentos do cliente, e otimização do fluxo de trabalho e processos da empresa (TERZI et. al 2010).

Na prática, a implementação do PLM depende fortemente de uma arquitetura de informações holística que integra dados, informações e sistemas heterogêneos (WANG et. al 2021; HINES et. al 2006). De forma que contempla uma ampla gama de atividades de engenharia, negócios e gerenciamento ao longo de todo o ciclo de vida do produto, desde a concepção de um conceito intangível até a disposição de um produto acabado (STARK 2015). Do ponto de vista da coleta de dados, os autores dividiram o PLM em nove etapas, incluindo conceito do produto, design, compra de matéria-prima, manufatura (que envolve fornecimento de material, planejamento de produção, manufatura e logística/armazenamento), transporte, venda, utilização, serviço pós-venda e reciclagem/descarte (TAO et. al 2017).

Dentre as inovações na área de gestão do produto, está a intersecção entre PLM e inteligência artificial, as técnicas computacionais alavancam a gestão do produto nos âmbitos de design de produto, manufatura e operação.

2.3.1.1. Design do produto

O design do produto orientado por dados e inteligência artificial visa otimizar detalhes do design ao explorar as diferenças entre requisitos do produto e esquemas de design (WANG et al., 2021). A utilização de Machine Learning para o design de produtos, tem como técnica a análise de mercado baseada em mineração de dados, que permite desenvolver produtos populares e inovadores não se pode separar o processo de uma adequada investigação de mercado (KAUR & KANG, 2016), influenciando intimamente a perspectiva de mercado, a aceitação do cliente e o ciclo de vida do produto (CHEN et. al 2006). O objetivo da análise de mercado é identificar clientes-alvo, reconhecer suas necessidades e transformar essas necessidades em características do produto (WANG et al., 2021). Comparado com a análise de mercado manual, a pesquisa de mercado baseada em Machine Learning pode descobrir a associações implícitas nos dados do mercado e estatísticas (ZHANG et. al 2015).

2.3.1.2. Manufatura do produto

A inteligência artificial contribui para o aprimoramento do processo de manufatura de produtos principalmente de duas maneiras: otimizando a execução e o processo de gestão de manufatura através de algoritmos de Machine Learning e substituindo o trabalho humano por dispositivos de IA (WANG et al., 2021). O processo de manufatura de produtos aprimorado por Machine Learning inclui avaliação, comparação e seleção de fornecedores para aquisição de materiais, configuração de recursos, planejamento de produção, usinagem, montagem, controle de qualidade, armazenamento, logística, entre outros (WANG et al., 2021). Para os fabricantes, a configuração ótima de recursos precisa levar em conta uma série de fatores como características do produto, objetivos corporativos, necessidades do cliente e diferentes combinações de recursos (HE & XU 2015). O planejamento de produção é essencial para organizar o processo produtivo, consumíveis e recursos de manufatura no chão de fábrica (por exemplo, máquinas de processamento, equipamentos de transporte e operadores), influenciando o custo de produção, eficiência na utilização de recursos e o tempo de entrega do pedido. Para situações mais complexas e dinâmicas, os algoritmos de planejamento inteligente são fortemente recomendados como solução para os problemas mencionados (CHEN et. al 2017).

2.3.1.3. *Operação do produto*

Inteligência artificial suporta o estágio de operação do produto de duas maneiras principais: sistema de atendimento ao cliente humanizado e monitoramento e manutenção inteligente de equipamentos remotos (Wang et al., 2021). Os serviços de vendas convencionais, caracterizados por avaliação e recomendação de produtos baseadas em regras, apresentam limites de adaptação a cenários personalizados (LIU & SHIH 2005). Como gerar recomendações de produtos informadas, levando em conta as necessidades dinâmicas do cliente e as características específicas do produto (CHEN et. al 2010). Com a utilização de big data na área de vendas, a aplicação combinada de Machine Learning e algoritmos de recomendação é possível melhorar o nível de decisão personalizada de recomendação, analisando as informações associadas à demanda do conjunto de usuários e do conjunto de produtos (BETRU et. al 2017). Além disso, algoritmos baseados em séries temporais, como os utilizados nesta dissertação, podem extrair características de preferência com base nos comportamentos históricos de compra do usuário e fazer recomendações modelando o conteúdo das vendas do produto e do grupo de usuários (HU et. al 2015).

2.3.2. *Gestão de preço*

Oferecer um desconto de preço para um produto não significa que o preço existente não seja ótimo, muitos benefícios acompanham a promoção, incluindo o reconhecimento do nome do varejista online, a conscientização do produto e da marca, a liquidação de estoques e a discriminação de preços, todos aumentando a exposição para clientes existentes e novos e melhorando as vendas de produtos (WALTERS, 1991; LEEFLANG et al., 2008). Em resumo, desconto de preço e recomendação de produto são naturalmente acoplados pela perspectiva da promoção. No entanto, essas duas estratégias são tradicionalmente abordadas de forma independente e otimizá-las simultaneamente é um novo conceito (JIANG et. al 2015). A literatura recente mostra que um dos principais papéis da recomendação de produto é influenciar a opinião dos clientes, o que por sua vez muda as utilidades esperadas (ou preços de reserva) dos produtos (BODAPATI, 2008).

De acordo com Jiang et. al (2015), a obtenção do melhor efeito na decisão de compra de clientes pode ser alcançada através da otimização conjunta da promoção de preços e recomendação de produtos, pois a perda com o desconto pode ser compensada pelos ganhos com os itens regulares. No contexto do comércio eletrônico, este foi empoderado pela tecnologia da informação, que possibilita o oferecimento de serviços de valor agregado aos

clientes, com redução de custos de busca na web e recebimento de informações valiosas sobre produtos por meio de recomendações online (JIN & SU, 2009). Além disso, os efeitos de substituição permitem compreender o comportamento de compra dos clientes para fornecer incentivos personalizados, coordenar atividades promocionais para diferentes produtos e categorias e projetar estratégias de correspondência para responder às campanhas promocionais dos concorrentes (JIN & SU, 2009).

2.3.3. Gestão da promoção

Promoções de vendas se referem a "uma coleção diversificada de ferramentas de incentivo, na maioria das vezes de curto prazo, projetadas para estimular compras maiores e mais rápidas entre os clientes-alvo" (KOTLER & ARMSTRONG, 2010, p. 408). Embora efetiva, Lahtinen et. al. (2020) demonstra evidências de que a gestão do composto de marketing (4P) de maneira integrada é mais eficaz do que uma campanha apenas de promoção (1P) para aumentar a ingestão de frutas e vegetais entre crianças.

De acordo com Zhang et. al (2019), em mercados maduros, os cupons de promoção são usados para induzir a mudança para o produto promovido, resultando em um aumento temporário nas vendas. Cerca de 244 bilhões (US\$ de cupons foram distribuídos em todo os EUA em 2018 com um valor total de face de 497 bilhões de dólares, segundo Kantar Media (2018). Estudos atuais sobre os efeitos entre categorias enfatizam o impacto de um produto na venda de outros. Por exemplo, Walters (1991) utilizou dados de nível de loja para examinar o impacto das promoções na compra de produtos complementares e substitutos. Juntamente com os efeitos entre lojas, ele testou o efeito de promoção dentro da loja para fornecer conselhos úteis para varejistas enfrentarem a concorrência. Gonzaez-Benito et al. (2010) propuseram um modelo para o preço ótimo, que é determinado pela concorrência na categoria do produto. Em vez de concorrência entre categorias, Bandyopadhyay (2009) modelou os efeitos dinâmicos das competições entre categorias e explorou o impacto da promoção nas vendas entre "categorias vizinhas" (por exemplo, sorvete, cobertura de sorvete e iogurte congelado).

2.3.4. Gestão da praça

Segundo a concepção original de McCarthy (1960), o elemento "Praça" (ou distribuição) no marketing se refere a: "onde", "quando" e "por quem" o produto será vendido. Assim, o termo "Praça" engloba decisões relacionadas aos canais de distribuição, à

variedade de produtos oferecidos, à localização das lojas, ao gerenciamento de estoque e ao transporte do produto. Para Neslin et al. (2006), um canal pode ser compreendido como um ponto de contato com o cliente, ou um meio pelo qual a empresa e o cliente interagem, este canal pode ser: (1) 'offline', como lojas físicas e catálogos, ou (2) 'online', como sites e plataformas de comércio eletrônico, ou (3) 'móvel', incluindo sites móveis e aplicativos. Enquanto o varejista multicanal oferece mais de um canal para os clientes interagirem e comprarem dele (TIMOUMI et. al 2022).

Para o contexto do comércio eletrônico, uma variedade de potenciais novos canais de distribuição emergiu, por exemplo os hotéis podem adotar para influenciar o comportamento do consumidor, assim como para o setor de viagens online, que gerou subcategorias incluindo intermediários online, agências de viagens de rua, redes de hotéis, atacadistas, mídias sociais e aplicativos móveis e operadores turísticos (TIMOUMI et. al 2022). Esse crescimento criou desafios adicionais, pois a gestão de receitas em perspectiva tradicional focava anteriormente no controle de capacidade (TIMOUMI et. al 2022).

A indústria do varejo também está passando por uma transformação devido a muitos processos impulsionados pela digitalização, Hagberg et al. (2015) discutiram a criação de novas formas de locais de troca ou interfaces de varejo-cliente e a integração dos canais existentes. Dennis et al. (2014) delinearão três canais típicos para fazer compras: tradicional ou físico (ou seja, tijolo e argamassa), interação computacional baseada na web e dispositivos móveis. Atingir a integração dos três canais (físico, online e móvel) e permitir que os clientes comprem de maneira contínua entre eles foi descrito como o modelo de varejo omnichannel (JOCEVSKI et. al, 2019).

Os clientes estão interagindo cada vez mais com os varejistas por meio de vários canais durante o mesmo processo de compra (SIT et. al, 2018). Exemplos de como os clientes interagem com os varejistas incluem "showrooming" (ou seja, descobrir um produto em uma loja física, mas finalizar a compra online) e "webrooming" (ou seja, descobrir online, mas comprar offline). Esses são exemplos contemporâneos de diferentes comportamentos de compradores (SIT et. al, 2018).

2.4. COVID-19 no Brasil e no Mundo

Ao final de 2019 houve uma grande alteração ambiental que afetou a vida das pessoas no mundo, suscitada pela pandemia de COVID-19 decretada em 11 de março de 2020 (WORLD HEALTH ORGANIZATION, 2020). A pandemia da COVID-19 aumentou a percepção de risco dos indivíduos, visto que levou a milhões de casos infectados e centenas de milhares de mortes em todo o mundo (CAO et al., 2020; LIU et al., 2020; ZHOU, 2021).

Para Renner et al (2015), a percepção de risco envolve a análise de como os indivíduos pensam e sentem sobre os riscos que enfrentam, com evidências encontradas em 2009 ao longo dos surtos de saúde causados pelo vírus A/H1N1 (gripe suína) sobre o sucesso dos programas de intervenção em saúde pública dependerem em grande parte da percepção de risco individual. Sendo o risco objetivo definido como a probabilidade de realização de resultados negativos ponderados por sua gravidade, tendo respaldo tanto na teoria da utilidade esperada quanto em economia e psicologia (WOLFF et al 2019). O risco percebido/subjetivo envolve uma avaliação cognitiva que pode ser fortemente influenciada ou guiada pelo afeto, de modo a compelir as pessoas a avaliar a elaborar estimativas de risco de acordo com uma avaliação da gravidade e a probabilidade de possíveis resultados, ainda que subjetivamente e com erro (LOEWENSTEIN et al., 2001).

Neste sentido, a incerteza suscitada pelo surgimento da pandemia de COVID-19 altera a percepção do risco por meio do viés da disponibilidade e heurística do afeto (KAHNEMAN, 2011), já que a percepção de risco é um dos fatores que influencia a tomada de decisão de compra (KAHNEMAN, 2011; KOTLER, 2012). Pois mesmo anteriormente à emergência sanitária, Larson et. al (2018) evidenciou que desastres naturais como furacões, incêndios florestais e inundações podem afetar o comportamento de compras e gastos dos indivíduos. No contexto da pandemia, a percepção de risco e a ameaça de contágio novas preferências, aumento do uso de tecnologias para se distanciar socialmente (KIM et al. 2021). Com influência no processo de transição de compras em meios presenciais para as compras online, que influenciou as empresas a tornar a venda digital mais eficaz e acessível (KIM 2020). No setor hoteleiro, clientes revelaram atitudes positivas em relação a hotéis em que o atendimento se deu através de robôs, com a redução da exposição ao risco (KIM et al. 2021).

2.5. Gestão da demanda

A gestão de demanda no mercado de produção e comercialização de chocolates contempla uma das etapas constituintes do gerenciamento da cadeia de suprimentos (do inglês *supply chain management*, SCM). Atividade esta que essencialmente abrange a orquestração das atividades produtivas que se desdobram desde a obtenção e aquisição de matérias-primas até a entrega dos produtos finais aos usuários finais (HUGOS, 2011). Trata-se de uma coordenação estratégica que visa melhorar o desempenho a longo prazo das empresas individuais e das cadeias de suprimentos como um todo (COOPER; LAMBERT; PAGH, 1997). De modo que a gestão de *supply chain* eficiente tem o potencial de melhorar o valor do cliente e gerar uma vantagem competitiva sustentável para a empresa (PORTER, 1985; CHRISTOPHER, 1992).

A maioria das organizações se concentra na otimização de custos e na manutenção de níveis ideais de estoque para manter a satisfação do consumidor, particularmente na gestão *supply chain* para indústria alimentícia, em que previsões de demanda precisas permitem que antecipar decisões de produção e gestão de estoque (HUSNA et. al 2021). No entanto, é a incerteza associada a essa demanda que torna a gestão da cadeia de suprimentos muito difícil, porque quanto mais longas são as cadeias de suprimentos e quanto mais organizações envolvidas, mais difícil se torna coordená-las (SYNTETOS et. al 2016). O nível de complexidade para previsão da demanda conduz à necessidade de utilizar técnicas de previsão cada vez mais robustas, como as utilizadas nesta pesquisa com métodos de Machine Learning.

Segundo Habib, (2011), a previsão é o fator chave no planejamento e na tomada de decisões para gestão em *supply chain*, pois toda previsão apoia decisões no âmbito do planejamento de capacidade, planejamento de produção, planejamento de promoção e compras, entre outros. No pano de fundo da tomada de decisão em *supply*, os fatores como a globalização do mercado e a inovação tecnológica adicionam complexidade a todas as empresas (VOGEL & LASCH, 2016). Contudo, as inovações na área de tecnologia da informação também forneceram os sistemas para coletar, processar e analisar dados, em que as empresas podem reunir dados suficientes sobre seus produtos, clientes e concorrentes, integrar várias fontes de informação, realizar cálculos complexos e testar várias hipóteses a um baixo custo e em pouco tempo (ARBOLEDA-FLOREZ & CASTRO-ZULUAGA, 2023). Essa quantidade de dados pode alimentar os métodos de aprendizado de máquina como uma

solução para melhorar a precisão, otimizar o tempo de processamento e reduzir a interação humana em uma ampla gama de aplicações (YAO et al., 2018).

2.6. Inteligência artificial e *Machine Learning*

Prever as decisões e o comportamento de compra do consumidor é um importante para a administração de marketing em empresas, assim como saber quem detém probabilidade de comprar ou até quais produtos podem se tornar populares é útil para alocar recursos de forma eficiente nos departamentos de vendas e marketing (MARTÍNEZ et al., 2020). Recentes tecnologias de processamento de dados permitem às empresas captar sinais acerca do comportamento de consumo, que possibilitam realizar previsões sobre suas decisões de compra (PEKER et al., 2017). A era do *Big Data* adentrou as pesquisas de marketing (HAGEN et al., 2020), assim como Inteligência artificial [IA] e *Machine Learning* [ML], que é considerada uma subcategoria da IA (KUMAR et al., 2021), tendo sido aplicado em diferentes áreas como contabilidade (DING et al., 2020), finanças (STROIE et al., 2014) e atendimento ao cliente (JAIN & KUMAR, 2020) devido à capacidade de identificar padrões em dados e permitir uma melhor tomada de decisão.

Ngai et. al (2022) conceitua IA como o uso de ferramentas computacionais para emular capacidades inerentes aos seres humanos em termos de tarefas físicas, mecânicas ou em processos como pensar e sentir. Dentre as atividades que IA foi projetada para executar destacam-se as que o reconhecimento de padrões e regularidades em dados se faz determinante, além da automatização de tarefas repetitivas e rotineiras que incluem soluções para sensoriamento remoto, tradução automática, algoritmos de classificação, algoritmos de agrupamento e redução de dimensionalidade (HUANG & RUST 2018; HUANG et al. 2019). Enquanto ML contempla um conjunto de ferramentas de análise e algoritmos utilizados para gerar previsões que subsidiam a tomada de decisão (AGRAWAL et al., 2018). Algumas tecnologias atuais incluem análise de sentimentos, processamento de linguagem natural [NLP], tecnologia de conversão de texto em fala, redes neurais recorrentes [RNN], *chatbots* para imitar a comunicação humana, agentes virtuais que intermedeiam interações humanas, como o *IBM Watson* (MCDUFF & CZERWINSKI 2018). Dividindo-se a tecnologia de ML nas seguintes subcategorias: *supervised learning*, *unsupervised learning*, *semi-supervised learning* e *reinforcement learning*.

- *Supervised learning*: consiste na previsão de uma variável dependente a partir de um conjunto de variáveis independentes, utilizando-se de algoritmos que realizam previsões de rótulos futuros empregando os dados rotulados disponíveis no conjunto de dados em uma variável dependente, que é prevista a partir de um determinado conjunto de variáveis independentes. Os algoritmos podem ser usados para prever rótulos empregando os dados rotulados disponíveis no conjunto de dados (MA & SUN, 2020). Essa tecnologia pode ser aplicada nas áreas de engajamento, previsão de *churn* de engajamento, recomendação, detecção de informações falsas, estratégia de marketing, previsão de decisão de compra, segmentação de clientes, previsão de demanda e gerenciamento de publicidade, com algoritmos como *k-nearest neighbors* [KNN], *Naïve Bayes*, *support-vector machine* [SVM], *Random Forest*, *XGBoost* [XGB] e regressão logística (NGAI et. al 2022). Grupo de técnicas utilizadas no presente estudo.
- *Unsupervised learning*: diferentemente do método anterior, ao invés de prever um resultado específico, as variáveis independentes são usadas para realizar agrupamentos por similaridade/proximidade (NGAI et. al 2022). Utilizando-se de algoritmos que reconhecem padrões em dados que não apresentam rótulos prévios, cujo objetivo típico é encontrar padrões ocultos ou extrair informações dos dados (MA & SUN, 2020). Essa tecnologia pode ser utilizada para segmentar indivíduos com base na semelhança do conteúdo de suas postagens de mídia social, segmentação de mercado, detecção de informações falsas, campanhas de segmentação, previsão de segmentação com algoritmos como *k-means*, *hierarchical clustering* (NGAI et. al 2022) e *principal component analyses* [PCA] que é considerado um método para redução de dimensionalidade para lidar com conjuntos de dados com grande de atributos maneira performática (KUHN & JOHNSON, 2013).
- *Semi-supervised learning*: através da combinação entre dados não rotulados e amostras de variáveis dependentes rotuladas, contempla uma integração entre *Supervised* e *Unsupervised learning* (REINDERS et. al 2019) que captura a estrutura discriminativa global dos dados para realizar a inferência acerca do rótulo da variável dependente ainda não rotulada, lidando efetivamente com o problema de informações de supervisão insuficientes (JIAN et. al, 2021). Podendo-se aplicar essa tecnologia, por exemplo, para prever traços de personalidade com base em postagens de mídia

social com base numa pequena amostra de dados rotulados e inferir a personalidade de indivíduos em a necessidade de aplicação massiva de *quizzes* e pesquisas que podem ser custosas (HAGEN et al., 2020). Utilizando-se de algoritmos como *Gaussian mixture model* [SSGMM], *transductive SVM* [TSVM]) e métodos baseados em grafos (JIAN et. al, 2021).

- *Reinforcement learning*: trata-se de um método que não depende de conjuntos de dados rotulados, que consiste em um mecanismo de recompensa e punição em que o algoritmo é recompensado por movimentos certos e punido por movimentos errados para tomar decisões precisas, em que a máquina aprende com experiências passadas e treina-se continuamente por tentativa e erro (WIERING & OTTERLO, 2012). Carros autônomos são uma aplicação amplamente conhecida desse método, além de aplicações nas áreas de recomendação, publicidade e previsão de segmentação (NGAI et. al 2022), com algoritmos como *Q-learning*, *multi-armed bandit*, *randomized-by-action*, and *off-policy evaluation* (WEI et al., 2005).

2.6.1. Interpretabilidade de modelos de inteligência artificial e Machine Learning

A contribuição das variáveis para a previsão geral de um modelo de Machine Learning utiliza da técnica de valor de Shapley (*SHAP value*, do inglês), uma abordagem da teoria dos jogos que calcula a contribuição marginal de cada característica para compor uma previsão (SHAPLEY, 1953). De acordo com a abordagem, os valores das características cooperam para alcançar a previsão para uma instância particular e se generalizam com a atribuição de características aditivas (ANTIPOV & POKRYSHEVSKAYA, 2020). Ou seja, o valor de Shapley representa a contribuição de cada variável respectiva em relação ao valor previsto comparado à previsão média para o conjunto de dados. A ideia por trás dos valores de Shapley é avaliar cada combinação de preditores para determinar o impacto de cada preditor (ARIZA-GARZON et. al 2020)

Em outras palavras, este é um conceito que nos ajuda a entender quanto cada uma das variáveis de um modelo contribui para o seu resultado. Suponha cada variável seja como um jogador em uma equipe, e o objetivo é ganhar um jogo. O valor de Shapley teria como *output* quanto cada jogador contribuiu para alcançar o objetivo. Isso é feito avaliando todas as

possíveis combinações das jogadas e ações realizadas. Com isso, o valor de Shapley não apenas nos diz quão importante é cada jogador individualmente, mas também como eles trabalham juntos. Dessa forma, é possível otimizar seus esforços individuais, entendendo melhor quais atividades que estão realmente fazendo a diferença no resultado.

Este estudo concentra-se no uso do método SHAP (*SHapley Additive exPlanations*) proposto como um recurso para explicar o processo de tomada de decisão por trás de um modelo de previsão (MARCILIO et. al 2020; MONCADA-TORRES et. al, 2021). O método SHAP fornece uma base teórica robusta para interpretar modelos de previsão, representando a influência de cada variável na saída do modelo enquanto garante consistência e estabilidade do modelo (MENG et al., 2020). Ao propor a inclusão do SHAP na automação do processo de previsão, tem-se em vista reduzir a fricção em todo o processo de Planejamento de Vendas e Operações (S&OP) em relação à implementação de algoritmos de aprendizado de máquina. Com resultados de previsão interpretáveis minimiza-se o risco de falha do projeto, com incremento na confiança com o modelo de modo a levar à adoção completa da nova tecnologia, aumentando, em última análise, a resiliência da empresa ao se adaptar às inovações tecnológicas e lidar com a incerteza crescente na demanda.

2.7. Construção de hipóteses

Esta seção da pesquisa delinea as hipóteses fundamentais que serão avaliadas ao longo do estudo. A pesquisa busca examinar a influência das estratégias de marketing nas vendas de chocolate durante a pandemia de COVID-19, assim como as etapas de consideração das hipóteses que sustentam os objetivos específicos até a construção do objetivo geral. Como se observa a seguir.

2.7.1. Hipóteses

A influência das estratégias de marketing nas vendas de chocolate pode ser compreendida ao considerarmos a gestão do composto de Marketing, que de acordo com Kramoliš & Kopečková (2013) trata de uma abordagem crucial para estabelecer uma vantagem competitiva, determinando como a empresa competirá em seus mercados-alvo. Além disso, Lahtinen et al., (2020) e Rahmani et al., (2015) reforçam que os 4Ps são uma estratégia aplicável tanto para negócios de grande quanto de pequena escala para aumentar as vendas. No âmbito do produto, estratégias como a utilização de Machine Learning para o design de

produtos podem levar ao desenvolvimento de produtos populares e inovadores através da análise de mercado baseada em mineração de dados (KAUR & KANG, 2016).

Conforme indicado por Walters (1991) e Leeflang et al. (2008), promoções de preços podem levar a benefícios como conscientização do produto e da marca, e liquidação de estoques, todos contribuindo para o aumento das vendas. Jiang et al. (2015) também ressaltam que a otimização conjunta da promoção de preços e recomendação de produtos pode melhorar o efeito na decisão de compra dos clientes. Do mesmo modo, a promoção inclui incentivos e estratégias de curto prazo para estimular compras maiores e mais rápidas entre os clientes-alvo (Kotler & Armstrong, 2010). Com base no potencial de influência das estratégias de marketing no consumo dos clientes em diversos mercados e abordagens estratégicas, foi desenvolvida a primeira hipótese da pesquisa:

H1: as estratégias de marketing utilizadas pela empresa influenciaram as vendas de chocolate no período

Ao final de 2019 houve uma grande alteração ambiental que afetou a vida das pessoas no mundo, suscitada pela pandemia de COVID-19 decretada em 11 de março de 2020 (WORLD HEALTH ORGANIZATION, 2020). A pandemia da COVID-19 levou a milhões de casos infectados e centenas de milhares de mortes em todo o mundo (CAO et al., 2020; LIU et al., 2020; ZHOU, 2021). Este contexto de incerteza suscitado pelo surgimento da pandemia de COVID-19 altera a percepção do risco por meio do viés da disponibilidade e heurística do afeto (KAHNEMAN, 2011), já que a percepção de risco é um dos fatores que influencia a tomada de decisão de compra (KAHNEMAN, 2011; KOTLER, 2012). Sudigdo et. al (2019) sugerem que a maneira como o marketing foi utilizado durante a crise da COVID-19 se assemelha e continuará a se assemelhar à forma como o marketing é realizado durante as recessões econômicas.

Durante circunstâncias de retração econômica as medidas gerais mais conhecidas incluem a redução de custos, corte da produção, redução de investimentos, entrada em mercados estrangeiros, trabalho com mais capital próprio, melhoria da eficiência e reestruturação da dívida (HALUK KÖKSAL & ÖZGÜL 2007). Roberts (2003) propôs um estudo sobre quais investimentos estratégicos você deveria fazer para ganhar a competição durante uma recessão, como aumentar os gastos com marketing, ou pelo menos manter o nível de antes da crise. Enquanto as evidências encontradas pelo estudo de Haluk Köksal & Özgül (2007)

mostraram que as empresas que aumentaram os gastos com marketing durante a recessão não foram menos lucrativas, pois seus lucros cresceram mais rápido na recuperação em comparação às que cortaram o orçamento de marketing. Além disso, essas empresas ganharam participação no mercado três vezes mais rápido.

Shama (1978, p. 50) evidenciou que uma crise econômica força uma mudança significativa nas decisões de preço das empresas, geralmente na direção de reduções, com o propósito de aumentar o volume de vendas a curto prazo, mas essa estratégia pode causar sérios danos a uma empresa a longo prazo, diminuindo a lucratividade. Isso também pode prejudicar a imagem da marca, e os clientes podem resistir a movimentos para retornar aos níveis de preço anteriores quando a crise terminar. Com base na incerteza que a crise da pandemia suscitou, foi elaborada a segunda hipótese da pesquisa:

H2: estratégias de marketing tiveram efeitos diferentes nas vendas comparando-se o período pré-pandemia e pandemia

A pandemia acarretou mudanças no padrão de consumo, por exemplo, reduzindo as vendas de categorias de vestuário e melhorando as vendas de outras categorias como de entretenimento digital (DEGLI ESPOSTI et. al, 2021). No setor de transportes aéreos, desencadeou-se um choque na demanda em todo o mundo, no Brasil como resultado da queda na atividade econômica e da crise de saúde as viagens aéreas caíram 81%, num mercado que apresentou R\$ 45,7 milhões de receita ao longo do segundo e terceiro trimestres de 2019 para apenas R\$ 8,7 milhões no mesmo período de 2020 (SANTOS et. al, 2021). De acordo com HOBBS (2021), no Canadá durante as primeiras semanas e meses da pandemia, as cadeias de suprimentos de alimentos foram sujeitas a vários choques acentuados de demanda e oferta que derrubaram as operações. Sendo a mais significativa a mudança de “serviço de alimentação” para o “varejo de alimentos”, pois as pessoas evitavam restaurantes e locais públicos por medo de infecção, e os governos impuseram bloqueios em uma tentativa de conter a propagação do vírus. O *Bureau of Labor Statistics* (2022) divulgou que em 2019 o gasto médio individual dos americanos em entretenimento foi de U\$ 3.148, comparado a U\$2.912 em 2020 com decréscimo de 8,5%, para serviços de beleza reduziram em 24% e despesas com moradia aumentaram 3,5%. De acordo com Quelch & Jocz (2009), contextos de recessão econômica e prejudicam o consumo, haja visto que o consumo depende da renda disponível e a expectativa de confiança em relação ao futuro econômico. Além de mudanças em certas variáveis econômicas, como taxa de juros e inflação, poderem afetar

significativamente os planos estratégicos de uma empresa (CHOI, 2003; LEE et. al, 2012). Por exemplo, no setor de restaurantes, as vendas dependem do indicador econômico de renda disponível dos turistas ou residentes (LEE et. al, 2012). De acordo com as evidências de Riley (2006), uma diminuição de 1% no indicador de renda disponível reduziria as vendas em viagens e restaurantes e hotéis em 4,5% e 9,3%, respectivamente. Com base nas evidências em outros mercados do impacto de indicadores econômicos nas vendas, foi elaborada a terceira hipótese:

H3: o desempenho dos indicadores econômicos brasileiros teve impacto na venda de chocolates da empresa analisada

No que compete às alterações nas decisões de compra dos consumidores, no mercado italiano, DI CROSTA et. al (2021) conduziu uma pesquisa que revelou que com a emergência do COVID-19 enfatizou-se a utilidade de bens essenciais (por exemplo, alimentos, medicamentos etc.) em comparação com produtos não essenciais (por exemplo, itens de luxo, como roupas e acessórios). Indicando-se também um aumento de 61% nos níveis de gastos durante a primeira semana das medidas de contenção sanitária. Além disso, os níveis de gastos aumentaram de forma diferente para a compra de produtos enquadrados como necessidades com 91% de aumento e não necessidades 36%. Na área rural, Mahmud et. al (2021) apresentou evidências que com o surgimento da COVID-19 famílias em Uganda diminuiu-se em 50% os gastos com alimentos por adulto, enquanto por volta de 50% das reservas monetárias foram utilizadas com aumento de volume de empréstimos na ordem de 100%. Desse modo, foi desenvolvida a quarta hipótese:

H4: a pandemia afetou negativamente a tendência de vendas de chocolates

O surto de COVID-19 mudou a maneira como trabalhamos, nos comunicamos e compramos, mais do que qualquer outra interrupção nesta década, sendo não apenas uma crise de saúde, mas uma fonte de alteração social e econômica (DI CROSTA et. al, 2021). De acordo com um estudo realizado pela *Nielsen Company*, a pandemia de COVID-19 alterou os níveis de gasto e consumo dos indivíduos, observando-se especialmente uma tendência crescente na venda de bens de primeira necessidade: as prioridades dos consumidores passaram a se centrar nas necessidades mais básicas, incluindo alimentação, higiene e produtos de limpeza (NIELSEN, 2020). Observou-se uma tendência de consumo motivada por comportamento compulsivo na compra de bens essenciais, especialmente relacionados à

prevenção do vírus, como dispositivos de proteção e gel desinfetante (CANNITO, 2021). Desse modo, foi desenvolvida a quinta hipótese:

H5: a pandemia alterou o padrão sazonal de vendas de chocolates

Anteriormente à emergência sanitária, Larson et. al (2018) evidenciou que desastres naturais como furacões, incêndios florestais e inundações podem afetar o comportamento de compras e gastos dos indivíduos. No contexto da pandemia, a percepção de risco e a ameaça de contágio promovem novas preferências, como o aumento do uso de tecnologias para se distanciar socialmente (KIM et al. 2021). Com influência no processo de transição de compras em meios presenciais para as compras online, que influenciou as empresas a tornar a venda digital mais eficaz e acessível (KIM 2020). No setor hoteleiro, clientes revelaram atitudes positivas em relação a hotéis em que o atendimento se deu através de robôs, com a redução da exposição ao risco (KIM et al. 2021). A percepção de risco, que é uma avaliação cognitiva, pode ser fortemente influenciada pelo afeto, levando as pessoas a estimar riscos baseados na gravidade e probabilidade de resultados possíveis, mesmo que de forma subjetiva e passível de erro (LOEWENSTEIN et al., 2001). Com base nesse panorama de interação com a intensidade da pandemia foi criada a sexta hipótese:

H6: as vendas de chocolates foram influenciadas de acordo com a variação dos índices associados à COVID-19, diminuindo com o agravamento e aumentando com a melhoria destes índices.

3. MÉTODO

A seção de método do presente estudo é dividida em duas subseções. A primeira seção apresenta a etapa qualitativa da pesquisa e a segunda seção apresenta a sua etapa quantitativa.

3.1. Método para 1ª etapa: estudo qualitativo

3.1.1. Tipo de pesquisa

A primeira etapa do método é classificada como uma pesquisa qualitativa exploratória. De acordo com Malhotra (2011) a pesquisa qualitativa é caracterizada pelo uso de pequenas amostras, com uma abordagem de coleta de dados não estruturada que tem como foco a compreensão do fenômeno de interesse de uma maneira mais profunda e holística. Ademais, a pesquisa exploratória é definida como uma pesquisa conduzida para ganhar insights e compreender melhor o problema investigado (MALHOTRA 2011). Esse tipo de pesquisa se caracteriza pela flexibilidade e uso frequente de métodos mais abertos de coleta de dados, como entrevistas não estruturadas e observação participativa, com grande utilização para definir termos, esclarecer conceitos e hipóteses e identificar as variáveis a serem estudadas (MALHOTRA 2011).

3.1.2. Coleta de dados

A coleta de dados qualitativos foi conduzida para realizar o primeiro objetivo específico desta dissertação, de modo a investigar as estratégias de marketing adotadas durante a pandemia de COVID-19, foram entrevistados quatro gestores das áreas de *Supply Chain*, *Trade Marketing* e Finanças para responder a perguntas específicas sobre como a pandemia afetou as operações da empresa, quais foram as principais estratégias de marketing adotadas durante a pandemia, se houve mudanças na estratégia de marketing da empresa durante a pandemia e quais foram os resultados dessas estratégias. Os dados coletados são do tipo primário, pois foram coletados especificamente para a proposta apresentada (MALHOTRA, 1996).

O método escolhido para a pesquisa foi de pesquisa em profundidade, uma técnica qualitativa que permite a obtenção de informações detalhadas e ricas em contexto sobre as experiências, percepções e comportamentos dos entrevistados (GRANOT & GREENE, 2014; FISCHER et. al. 2014). A pesquisa busca entender como a empresa estudada lidou com os desafios impostos pela pandemia e quais foram as estratégias de marketing mais eficazes para

superar esses desafios. Além disso, também foi objeto da pesquisa a análise de como a empresa planeja continuar a usar as estratégias de marketing que foram bem-sucedidas durante a pandemia no futuro. As perguntas realizadas na pesquisa foram de acordo com o Quadro 1.

Quadro 1 - Pergunta aos gestores

P1 - Qual seu cargo na empresa?
P2 - Trabalha há quanto tempo na empresa?
P3 - Como a pandemia de COVID-19 afetou as operações da empresa de chocolates?
P4 - Quais foram as principais estratégias de marketing que a empresa adotou durante a pandemia?
P5 - A empresa mudou sua estratégia de marketing durante a pandemia? Se sim, de que forma essas estratégias foram diferentes das estratégias adotadas antes da pandemia?
P6 - Quais foram os resultados das estratégias de marketing adotadas pela empresa durante a pandemia?
P7 - Como a empresa planeja continuar a usar as estratégias de marketing que foram bem-sucedidas durante a pandemia no futuro?

Estas perguntas foram feitas para quatro gestores da organização estudada. As entrevistas foram realizadas de forma online por meio do software livre de comunicação virtual chamado Google Meet. A descrição da coleta de dados é apresentada na Tabela 1.

Tabela 1 - Resumo dos entrevistados

Codificação	Cargo na empresa	Tempo de empresa	Duração da entrevista	Data da entrevista
E1	Executivo de Supply Chain	21 anos	31 min	27/11/2022
E2	Gerente de Supply Chain	8 anos	45 min	16/09/2022
E3	Gerente de Trade Marketing	15 anos	45 min	14/03/2023
E4	Gerente de Finanças	6 anos	45 min	19/09/2022

3.1.3. *Análise dos dados qualitativos*

A análise de dados da parte qualitativa do presente estudo foi feita por meio de análise de conteúdo e categorização dos dados. De acordo com Bardin (2011), a análise de conteúdo concerne a um conjunto de técnicas de análise das comunicações visando obter por procedimentos sistemáticos e objetivos para a descrição do conteúdo das mensagens. Ademais, a categorização é definida por Bardin (2011) como o processo de classificar os dados em diferentes grupos ou classes que compartilham características comuns, em que esses temas ou padrões se tornam as categorias que ajudam a organizar os dados de maneira que permita uma análise estruturada mais organizada e profunda dos conteúdos obtidos.

3.2. Método para 2ª etapa: estudo quantitativo

3.2.1. *Tipo de pesquisa*

A segunda etapa do presente estudo é classificada como uma pesquisa quantitativa longitudinal com finalidade descritiva que utiliza dados secundários internos de uma multinacional do setor alimentício. De acordo com Malhotra (2011), a pesquisa descritiva tem como objetivo elaborar descrições sobre um grupo de indivíduos ou sobre o mercado como um todo. Enquanto a abordagem longitudinal acompanha mudanças ao longo do tempo, analisando repetidamente indivíduos com as mesmas variáveis. Já a metodologia quantitativa baseia-se em dados estruturados para generalizar resultados de uma amostra para a população de interesse. Esses dados podem ser obtidos por meio de pesquisa de campo ou de dados secundários, que são informações já coletadas para outros fins, mas que podem ser úteis para fins de pesquisa.

3.2.2. *Coleta de dados*

Nesta seção será apresentada a coleta dos dados de variável dependente (volume de vendas) e variáveis independentes (investimento de marketing, índices econômicos, indicadores de COVID-19).

3.2.2.1. Coleta de dados de volume de vendas e investimento em marketing

O autor da pesquisa trabalha na empresa estudada, na área de previsão de demanda e operações e possui acesso e permissão para utilização de dados. Desta forma, sobre volume de vendas de chocolate foram coletados diretamente dos bancos de dados relacionais corporativos. Os dados contemplam o período de maio de 2018 até dezembro de 2022, sendo que a extração dos dados ocorreu por meio de ferramentas de banco de dados relacionais, em linguagem de consulta estruturada.

A obtenção dos dados de volume de vendas de chocolates, assim como o valor monetário desembolsado pela empresa com estratégias de marketing foram obtidos das informações internas da empresa sendo que as informações pessoais foram recebidas de forma anonimizada em acordo com o cenário de segurança jurídica implementado pela Lei Geral de Proteção de Dados [LGPD], os dados utilizados não permitem identificar, direta ou indiretamente, qualquer indivíduo do estudo. Os dados de volume de vendas foram transformados da unidade de medida Kg para Tonelada e os valores foram deflacionados.

3.2.2.2. Coleta de dados de inflação, taxa de desocupação, nível de atividade econômica do comércio e poupança

As variáveis independentes externas à empresa utilizadas no presente estudo foram o Índice Nacional de Preços ao Consumidor Amplo [IPCA] que compete ao índice oficial de inflação do Brasil, a taxa de desocupação que mede a porcentagem de pessoas na força de trabalho que estão desempregadas, ambas variáveis disponibilizadas pelo Instituto Brasileiro de Geografia e Estatística [IBGE] e também o nível de atividade do Comércio varejista ampliado, uma medida da atividade econômica do setor varejista, que inclui as vendas de mercados, supermercados, veículos, autopeças e materiais de construção, além dos itens tradicionalmente considerados no varejo. Esta variável é disponibilizada pelo Instituto de Pesquisa Econômica Aplicada [IPEA]. Para os dados de montante depositado em poupança em valores absolutos e captação líquida em poupança foram utilizados os dados da autoridade monetária nacional, Banco Central do Brasil [BACEN].

3.2.2.3. Coleta de dados de pesquisas no Google e novos casos de Covid no Brasil

Para avaliar como o agravamento da pandemia da COVID-19 afetou as vendas de chocolates, foram utilizados os dados de novos casos no Brasil, divulgados oficialmente pelo Ministério da Saúde através do Painel Coronavírus, bem como o interesse de pesquisa no Google sobre assuntos relacionados à COVID-19, obtidos pelo Google Trends. Este último fornece detalhes sobre a dinâmica dos interesses online dos usuários, incluindo a influência da mídia no pensamento coletivo (ROVETTA, 2021). Esta ferramenta tem sido amplamente explorada na comunidade científica para realizar estudos médicos, psicológicos, econômicos e até epidemiológicos (SOUSA-PINTO et al 2020; NUTI et al 2014; ASGARI et al, 2021; EFFENBERGER et al 2020). Trata-se de uma ferramenta fornecida pelo Google que disponibiliza o interesse de pesquisa dos usuários na Web em tópicos específicos ao longo do tempo, trazendo valores normalizados que são dimensionados em um intervalo de 0 a 100 com base na proporção de um tópico para todas as pesquisas (GOOGLE, 2022).

3.2.3. *Análise dos dados quantitativos*

Para realizar os tratamentos e manipulações dos grandes volumes de informações, serão utilizadas linguagens computacionais otimizadas para Big Data, como *Spark* e *PySpark*. Para os testes estatísticos, assim como o processo de modelagem estatística, foi utilizado *Python*. De modo a facilitar o entendimento, a seção de análise de dados quantitativos do presente estudo foi dividida por objetivo, conforme descrito nas próximas subseções.

3.2.3.1. Análise dos dados do objetivo específico II

O objetivo específico II consiste em verificar quais mudanças ocorreram nas vendas de chocolates ao longo da pandemia da COVID-19. Desta forma, a análise de dados para realização deste objetivo foi feita utilizando a técnica de decomposição de série temporal, a escolha dessa técnica se deu pela possibilidade de se analisar o comportamento de uma variável ao longo do tempo e identificar padrões e tendências (DAGUM, 2010).

A decomposição de série temporal permite a separação dos componentes de uma série em tendência, sazonalidade e resíduo, possibilitando uma análise mais detalhada das variações ocorridas. Além disso, foi utilizado a análise descritiva das variações, que nos permitiu compreender melhor as mudanças ocorridas em relação à tendência e sazonalidade. Com essas técnicas, foi possível identificar os trimestres em que as vendas apresentaram

mudanças significativas em relação à tendência e sazonalidade, contribuindo para uma melhor compreensão do impacto da pandemia nas vendas de chocolates.

3.2.3.2. Análise dos dados do objetivo específico III

O objetivo específico III é verificar como a percepção de risco da pandemia da COVID-19 afetou as vendas de chocolate no período analisado. Para realização deste objetivo os dados foram analisados com a técnica de correlação cruzada de Pearson que permite verificar se existe uma relação entre as vendas de chocolates e as variáveis independentes escolhidas ao longo do tempo. Além disso, os correlogramas foram utilizados para verificar a existência de uma relação de dependência entre as vendas de chocolates e as variáveis independentes, com base na análise da autocorrelação das séries temporais.

3.2.3.3. Análise dos dados do objetivo geral

O objetivo geral da presente pesquisa consiste em avaliar o efeito das estratégias de marketing adotadas ao longo da pandemia da Covid-19 nas vendas de chocolate de uma empresa que atua no mercado brasileiro. Para sua realização foi conduzida uma análise de dados por meio da utilização da técnica de Machine Learning para Regressão múltipla, tendo como Variável dependente as vendas de chocolates mensal de 2018 a 2022 e Variáveis independentes: nível de atividade do Comércio varejista ampliado, Índice Nacional de Preços ao Consumidor Amplo [IPCA], Captação líquida em poupança (R\$), Montante depositado em poupança (R\$), valores desembolsados nas Estratégias de marketing adotadas pela empresa ao longo do período. Para verificar se as variáveis independentes utilizadas possuem distribuições normais foram realizados testes de distribuição das mesmas, esses testes têm como objetivo verificar se as variáveis independentes seguem distribuições normais, o que é uma premissa importante para a aplicação do método de regressão OLS múltipla (PAUL & ZHANG, 2010). Para realizar os testes de distribuição, serão utilizados métodos estatísticos como o teste de Kolmogorov-Smirnov [KS], que testa a hipótese nula de que uma determinada amostra possui uma distribuição específica (no atual caso, distribuição normal) de modo a encontrar a maior diferença entre duas funções cumulativas (NORUSIS, 2005) e o teste de normalidade de Shapiro-Wilk que consiste na verificação se uma amostra de dados segue uma distribuição normal. Ele é baseado na comparação entre os dados observados e os valores esperados para uma distribuição normal. Se os dados não tiverem uma distribuição normal, o teste de Shapiro-Wilk [Shapiro] irá rejeitar a hipótese nula de que a amostra é distribuída de forma normal (SHAPIRO & WILK, 1965).

O modelo de regressão escolhido para a análise será o XGBoost, uma técnica de aprendizado de máquina que tem se mostrado eficaz em prever vendas e outras métricas de marketing (AKANDE et. al 2022). A explicação da análise de dados do objetivo geral é dividida em três etapas: Etapa A: Construção do modelo com algoritmo XGBoost, Etapa B: Avaliação dos resultados do modelo, Etapa C: Interpretabilidade utilizando Shap Value. Estas três etapas são discutidas a seguir.

Etapa A: Construção do modelo com algoritmo XGBoost

O modelo foi implementado usando a biblioteca XGBoost para Python através de um projeto de código aberto e domínio público. Esse algoritmo para modelagem preditiva pode ser utilizado tanto para classificação e regressão (AKANDE et. al 2022). O algoritmo de *extreme gradient boosting* (XGBoost) foi criado por Chen e Guestrin, sendo um algoritmo efetivo de aprendizado em conjunto baseado em árvores, é considerado uma ferramenta poderosa entre os pesquisadores de ciência de dados (CHEN & GUESTRIN, 2016). O XGBoost é baseado na arquitetura de *boosting* de gradiente (FRIEDMAN, 2001), este algoritmo é composto por múltiplas árvores de decisão através do método de descida do gradiente que é utilizado para gerar cada árvore. Com base em todas as árvores de decisão individuais, a otimização é realizada pela minimização da função de perda como objetivo (LIANG et. al., 2019).

O conjunto de dados utilizado para modelagem foi dividido em dois conjuntos: um conjunto de treinamento e um conjunto de teste. O conjunto de treinamento é usado para aprendizado do modelo durante o processo de desenvolvimento, enquanto o conjunto de teste foi usado para avaliar os resultados do modelo, técnica tradicional de avaliação de resultados de modelos de Machine Learning chamado de cross-validation (BERGMEIR & BENÍTEZ, 2012; WANG et. al, 2018; WESTERVELD et.al. 2021). Para este estudo foi utilizado a abordagem de cross-validation com a direção metodológica de Yenidogan et.al. (2020), com o conjunto de teste de 15% e conjunto de treinamento com 85% dos dados.

- Treino: 2018/05/01 - 2022/03/01

- Teste: 2022/04/01 - 2022/12/01

Um dos aspectos a se destacar na abordagem de série temporal com múltiplas variáveis é o indicador da existência de multicolinearidade entre as variáveis independentes. Caso haja a presença de multicolinearidade, os resultados da análise podem ser enviesados e instáveis. Para verificar a existência desse fator é possível examinar a matriz de correlação desses dados (HAIR et al., 1995), procedimento adotado nesta dissertação. Cabe ressaltar que duas das estratégias mais utilizadas para lidar com a multicolinearidade são: retirar uma das variáveis altamente correlacionadas da análise, ou combinar as variáveis correlacionadas em uma nova variável (MCDANIEL; GATES, 1996).

Etapa B: Avaliação dos resultados do modelo

Para avaliação dos modelos gerados foram utilizadas técnicas estatísticas tradicionais de séries temporais como *Akaike's information Criterion* (AIC) e *Bayesian information Criterion* (BIC), que podem ser utilizados tanto para seleção de modelos (HENDRAWATI et. al. 2019) como para avaliar autorregressões em séries temporais (BERGMEIR & BENÍTEZ, 2012). Além disso, também foi utilizado o teste *Durbin-Watson* como ferramenta estatística utilizada em séries temporais para verificar se há autocorrelação nos resíduos de um modelo de regressão. Ele produz um valor estatístico que varia de 0 a 4 e é um teste de hipótese que verifica se há autocorrelação de primeira ordem nos resíduos. Valores próximos a 2 indicam que não há autocorrelação nos resíduos, enquanto valores abaixo de 2 indicam autocorrelação positiva e valores acima de 2 indicam autocorrelação negativa. O teste é útil para verificar se um modelo de regressão é apropriado para uma série temporal e ajuda a identificar a presença de autocorrelação nos resíduos, permitindo fazer ajustes para melhorar a precisão das previsões (SHIVELY et. al. 1990; LARA et. al. 2020).

Para avaliar a qualidade de um modelo de regressão e selecionar o melhor modelo para prever a série foi utilizado o método R-quadrado (R^2), que é uma métrica usada em séries temporais para avaliar a qualidade de ajuste de um modelo de regressão. Essa métrica indica a proporção de explicabilidade da variável dependente através das variáveis independentes do modelo. O R-quadrado varia de 0 a 1, sendo que valores mais próximos de

1 indicam que o modelo explica uma maior proporção da variação da variável dependente. No entanto, é importante observar que um alto valor de R-quadrado não significa necessariamente que o modelo é adequado, pois pode haver outros fatores não incluídos no modelo que também afetam a variável dependente (WILEY & SON, 2016).

Outra métrica utilizada é o R^2 ajustado, que é uma versão do R-quadrado que leva em conta o número de variáveis independentes incluídas no modelo que penaliza os modelos com um maior número de variáveis independentes. A ideia central do R^2 ajustado é substituir os estimadores viesados por seus equivalentes não viesados (KARCH, 2020). Destaca-se também o uso das métricas MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*) e MAPE (*Mean Absolute Percentage Error*) são métricas de avaliação de modelo de regressão que medem a diferença entre os valores previstos e os valores reais. Essas métricas são comumente usadas para avaliar a precisão do modelo em termos de erros de previsão. Embora as três métricas avaliem a precisão do modelo de diferentes maneiras, elas podem ser resumidas em uma palavra como "erro" ou "diferença". As métricas de erro são usadas para medir a magnitude das diferenças entre os valores previstos e os valores reais, com o objetivo de avaliar o desempenho geral do modelo de regressão.

De maneira geral, um modelo econométrico é avaliado em sua capacidade preditiva por meio dos valores de R-quadrado ou R-quadrado ajustado, sendo que quanto mais alto esses valores, maior é a capacidade preditiva do modelo (GUJARATI et. al, 2012). Este princípio fomenta a confiança na efetividade das variáveis explicativas em prever a variável dependente (HILL et. al, 2018). No entanto, como esclarece Ozili (2022), a aceitabilidade do R-quadrado pode variar, por exemplo, um R-quadrado que oscila entre 0 e 0,09 (ou 0% a 9%) é considerado muito baixo para um modelo empírico em pesquisa de ciências sociais, sendo, portanto, tipicamente rejeitado. Por outro lado, um R-quadrado que está entre 0,10 e 0,50 (ou entre 10% e 50%, quando expresso em porcentagem) é considerado aceitável, mas apenas quando algumas ou a maioria das variáveis explicativas são estatisticamente significativas (OZILI 2022). Para valores de R-quadrado entre 0,50 e 0,99 tem-se que o modelo é aceitável, exceto quando um alto valor de R-quadrado ser consequência de causalidade espúria ou multicolinearidade entre as variáveis explicativas (OZILI 2022).

Etapa C: Interpretabilidade utilizando *Shap Value*

A interpretabilidade do impacto das variáveis independentes nas vendas de chocolates foi realizada com o método SHAP calculado de forma média e para cada mês da série temporal. Há duas abordagens majoritárias para se utilizar dos valores SHAP, uma que mostra valores positivos e negativos e outra que mostra o módulo (valores absolutos) dos valores SHAP. Para a abordagem com valores SHAP positivos e negativos, os valores SHAP indicam o quanto cada característica contribui para aumentar (valor positivo) ou diminuir (valor negativo) a previsão do modelo para uma instância específica, em relação ao valor de base (a média das previsões para todas as instâncias no conjunto de dados). Isso permite entender a direção da influência de cada característica na previsão do modelo. Para o módulo dos valores SHAP (valores absolutos), os valores SHAP são apresentados como seus módulos, ou seja, apenas os valores absolutos são considerados. Essa representação mostra a magnitude do impacto de cada característica na previsão do modelo, independentemente da direção (positiva ou negativa). Isso pode ser útil para compreender quais características têm o maior impacto geral na previsão, sem se preocupar com a direção dessa influência.

Ambas as abordagens têm suas aplicações e podem ser usadas de acordo com os objetivos de interpretação do modelo. Em geral, os valores SHAP positivos e negativos fornecem mais informações sobre a direção do impacto, enquanto o módulo dos valores SHAP pode ser útil para realizar comparações de magnitude do impacto entre variáveis. Para esta dissertação, implementou-se a abordagem de interpretabilidade desenvolvida por Lundberg & Lee (2017) com a contribuição marginal de cada variável para o output de um modelo. Abordagem essa também utilizada por Arboleda-Florez & Castro-Zuluaga (2023) para interpretar as previsões de demanda de vendas diretas, e para interpretação de modelos de previsão de vendas no varejo (ANTIPOV & POKRYSHEVSKAYA, 2020). O Quadro 2 resume a relação entre objetivos, procedimentos metodológicos e hipóteses.

Quadro 2 - Relação entre os itens dos procedimentos metodológicos

Objetivos	Descrição	Método	Técnica de análise	Hipótese
Específico I	Identificar quais foram as estratégias de marketing utilizadas pela empresa estudada no mercado de Chocolates ao longo da crise de COVID-19.	Qualitativo	Pesquisa em profundidade com gestores do mercado de Chocolates – Análise de conteúdo	----
Específico II	Verificar quais mudanças que ocorreram nas vendas de chocolates ao longo da pandemia da COVID-19	Quantitativo	Decomposição de série temporal de vendas e análise descritiva das variações em comparação com tendência e sazonalidade	H4: a pandemia afetou negativamente a tendência de vendas de chocolates H5: a pandemia alterou o padrão sazonal de vendas de chocolates
Específico III	Verificar como a percepção de risco da pandemia da COVID-19 afetou as vendas chocolates no período analisado	Quantitativo	Série temporal da correlação cruzada Variável dependente: vendas de chocolates em cada trimestre (Pré e pandemia) Variáveis independentes: Buscas pelo termo COVID-19 no Google Trends, Contagem de casos	H6: as vendas de chocolates foram influenciadas de acordo com a variação dos índices associados à COVID-19, diminuindo com o agravamento e aumentando com a melhoria destes índices.

Continua na próxima página

Conclusão do Quadro 2

Objetivos	Descrição	Método	Técnica de análise	Hipótese
Geral	Avaliar o efeito que as estratégias de marketing adotadas ao longo da pandemia da Covid-19 tiveram em vendas de chocolate de uma empresa que atua no mercado brasileiro	Quantitativo	Regressão múltipla com Machine Learning Variável dependente: vendas de chocolates mensal de 2018 a 2022 Variáveis independentes: Atividade econômica do comércio, Inflação, indicadores de poupança no Brasil, Taxa de desocupação, Estratégias de marketing Shap Value das variáveis independentes calculado para cada ponto do tempo	H1: as estratégias de marketing utilizadas pela empresa influenciaram as vendas de chocolate no período H2: estratégias de marketing tiveram efeitos diferentes nas vendas comparando-se o período pré-pandemia e pandemia H3: o desempenho da atividade econômica brasileira impactou a venda de chocolates da empresa analisada

4. RESULTADOS E DISCUSSÃO

Este capítulo apresenta os resultados na dissertação, inicialmente são mostrados os resultados da primeira etapa, isto é, a pesquisa qualitativa (objetivo específico I) que envolve a pesquisa em profundidade com gestores, em seguida são apresentados os resultados referentes às análises quantitativas, ou seja, segunda etapa do estudo que se refere aos objetivos específicos II e III assim como o objetivo geral da presente dissertação.

4.1. Objetivo específico I: apresentação das estratégias de marketing utilizadas pela empresa

Os gestores da empresa foram submetidos a uma pesquisa em profundidade, a qual revelou que foram adotadas diversas estratégias de marketing no âmbito de Publicidade, Relacionamento com cliente, Produto, Preço e Incentivo por meio de metas. Estas estratégias são descritas nas próximas seções.

4.1.1. Investimento em publicidade

A definição de investimento como publicidade é feita com base nos gastos financeiros realizados na criação e manutenção de materiais publicitários, bem como anúncios em mídias digitais, televisão e rádio (E1). Ao longo de uma das entrevistas, um entrevistado, identificado neste estudo como E1, declarou: "Antes da pandemia, nosso investimento em publicidade era direcionado principalmente para mídias tradicionais, como televisão e rádio. Durante a pandemia, decidimos alocar parte do nosso investimento para mídias digitais, como forma de alcançar um público mais amplo e adaptar nossa estratégia ao novo contexto". Enquanto o entrevistado identificado como E4, declarou: "Nós realizamos uma análise detalhada dos nossos gastos durante a pandemia e ajustamos nosso orçamento de publicidade para garantir que estávamos investindo de forma eficiente e com o melhor retorno possível."

De acordo com os entrevistados, as estratégias adotadas pela empresa na vigência da crise de COVID-19 seguiram em duas perspectivas, sendo a primeira com a revisão dos gastos e revisão orçamentária, pontos que caminham na mesma direção observada por Roberts (2003) em que as medidas gerais mais comuns em situações de crise incluem a redução de custos, corte de produção, diminuição de investimentos, entrada em mercados estrangeiros, trabalho com mais capital próprio, melhoria de eficiência e reestruturação de dívidas. Ou até que

momentos de crise levam a decisões gerenciais de marketing inclusive mais extremas como demissão de parte do corpo funcional além da redução de salários (ZEHIR & SAVI 2004). De maneira geral, Roberts (2003) propõe que as empresas devem planejar seus orçamentos de marketing a longo prazo e manter os gastos a curto prazo, a fim de sobreviver durante os tempos difíceis e ser lucrativos no futuro.

A segunda perspectiva adotada pela empresa concerne ao uso de estratégias digitais de venda, que segue na mesma direção da indústria de varejo impulsionada pela digitalização, que está passando por uma transformação significativa, envolvendo a criação de novos pontos de interação cliente-varejo e a integração de canais já existentes (HAGBERG et al., 2015). Três canais de compras se destacam nessa transformação: tradicional ou físico, interação online e dispositivos móveis (DENNIS et al., 2014). O modelo de varejo *omnichannel*, que busca integrar esses canais, tornou-se fundamental, permitindo que os clientes alternem facilmente entre eles (JOCEVSKI et al., 2019). A transição do presencial para o online tem sido influente, pressionando as empresas a tornarem suas vendas digitais mais eficazes e acessíveis (KIM, 2020). Essa mudança foi ainda mais evidente durante a pandemia, que alterou os padrões de consumo, beneficiando, por exemplo, a categoria de entretenimento digital em detrimento de categorias como vestuário (DEGLI ESPOSTI et al., 2021).

4.1.2. *Investimento em visibilidade de produto*

Caracteriza-se o investimento como produto quando o valor financeiro em reais é utilizado para alavancar a visibilidade do produto no ponto de venda com por exemplo a aquisição de gôndolas extras, paletes de exibição ou área da prateleira exclusiva (E2). Ao longo da entrevista, E1 deu a seguinte resposta: “O investimento em produto durante a pandemia foi fundamental para mantermos a visibilidade dos nossos produtos nos pontos de venda e garantir que os consumidores tivessem acesso a eles”. Enquanto o entrevistado E2 declarou que: “Além de garantir a disponibilidade dos nossos produtos nos momentos de alta procura, também investimos em estratégias para antecipar a demanda em momentos de baixa procura, de forma a manter uma oferta constante e atender às necessidades dos nossos consumidores durante o período.”

Os entrevistados evidenciaram que a estratégia de investimento em produto teve uma destacada importância e se desdobrou em visibilidade, antecipação da demanda e

atendimento da necessidade de consumo com oferta constante. Essas abordagens vão ao encontro da perspectiva de Habib (2011), que evidenciou serem as previsões essenciais para o planejamento e a tomada de decisões em gestão de cadeias de fornecimento, apoiando diversas áreas, desde a capacidade até o planejamento de promoções e compras. Mesmo oferecendo um desconto, muitos benefícios acompanham a promoção, incluindo reconhecimento do nome do varejista online, conscientização da marca, liquidação de estoques, e aumento da exposição para clientes (WALTERS, 1991; LEEFLANG et al., 2008). Ademais, as estratégias adotadas pela empresa para garantir a disponibilidade, antecipar a demanda e manter uma oferta constante para atender às necessidades dos consumidores seguem as práticas de inovação em produto que abarcam o advento da tomada de decisão baseada em big data, utilização de Machine Learning e algoritmos de recomendação podem melhorar a personalização das decisões de venda (BETRU et al., 2017; HU et al., 2015).

4.1.3. *Incentivo por meio de metas*

O investimento definido como incentivo de metas ocorre quando o ponto de venda atinge uma meta pré-estabelecida, ou seja, a empresa produtora do chocolate concede um desconto caso o ponto de venda atinja uma meta acordada. Esses descontos são contabilizados como investimentos que promovem o incentivo do ponto de venda a vender mais (E3). Nesse contexto, o entrevistado E3 fez o seguinte relato: “Realizamos um estudo de mercado para entender as mudanças nos hábitos de compra e consumo, e ajustamos nossa estratégia de trade marketing com foco em canais de venda online e em oferecer promoções e descontos atrativos para os consumidores.”

A estratégia da empresa de oferecer descontos atrelados a metas de vendas segue a diretriz definida por Jiang et al. (2015) sobre a melhor maneira de influenciar a decisão de compra dos clientes, que é por meio da otimização conjunta da promoção de preços e recomendação de produtos pois a perda com o desconto pode ser compensada pelos ganhos com os itens regulares. Além de promoções de vendas pertencerem à coleção de ferramentas de incentivo para estimular compras (KOTLER & ARMSTRONG, 2010). Além disso, os efeitos de substituição auxiliam na compreensão do comportamento do consumidor para fornecer incentivos personalizados e coordenar atividades promocionais (JIN & SU, 2009).

4.1.4. *Relacionamento com cliente*

O investimento de Relacionamento com cliente concerne ao valor pago às atividades não ligadas à performance dos clientes, como restauração de lojas, propagandas compartilhadas e ações promocionais em datas comemorativas dos PDVs (E4). O entrevistado E4 declarou: “Nós investimos em ações de relacionamento com o cliente ao longo da pandemia, buscando manter a proximidade e a fidelidade de nossos consumidores através de promoções, brindes e campanhas de marketing voltadas para as datas comemorativas. Também promovemos o engajamento nas redes sociais”. Ademais, o entrevistado E2 também comentou o tema com a seguinte fala: “Nós reforçamos nosso relacionamento antecipando suas necessidades e oferecendo soluções personalizadas, como promoções especiais e descontos em produtos selecionados. Além disso, investimos em treinamento e capacitação dos nossos representantes comerciais para que pudessem oferecer um atendimento ainda mais eficiente e satisfatório aos nossos clientes.”

Sobre o investimento em capacitação dos representantes comerciais como estratégia adotada pela empresa, Mason et. al, (2021) argumentam que ao longo do contexto de transformação digital acelerada pela pandemia, algumas lojas forneceram soluções inovadoras como treinamento de vendas digital, via WhatsApp ou FaceTime, e transmissões ao vivo que desempenham papéis importantes. Com os descontos especiais, a empresa adotou uma abordagem similar à investigada por Zhang et al. (2019) com cupons promocionais, que podem aumentar temporariamente as vendas e promover mudanças para produtos promovidos


4.2. Objetivo específico II: análise das mudanças que ocorreram nas vendas de chocolates ao longo do período pandemia da COVID-19

Esta seção tem como objetivo verificar as mudanças que ocorreram nas vendas de chocolates ao longo do período da pandemia da COVID-19. Para atingir este objetivo, foram utilizadas técnicas de decomposição da série temporal de vendas de chocolates, comparando esses valores de forma mensal e trimestral ao longo do período de maio de 2018 até dezembro de 2022. A análise dos dados permite avaliar como a pandemia afetou as vendas de chocolates e identificar possíveis mudanças nos padrões de vendas durante esse período desafiador. A decomposição da série temporal pode ajudar a identificar as tendências de

longo prazo e os padrões sazonais subjacentes, permitindo que a empresa tome decisões informadas com base nas informações obtidas


O Gráfico 1 permite visualizar a decomposição da série de vendas em, em que se observa a tendência de vendas positiva em toda série temporal, com acelerações e desacelerações entre anos, mas com alteração consistente a partir de novembro de 2020. Enquanto a sazonalidade pode ser vista como flutuações regulares nas vendas de um mês para outro em cada ano sem alterações de magnitude.

Gráfico 1 – Sazonalidade e Tendência de vendas



Agrupando a composição sazonal das vendas em trimestres é possível identificar que não houve alteração significativa do padrão de sazonalidade das vendas que se manteve desde 2018 concentrada no quarto trimestre do ano, como é possível constatar no Gráfico 2.

Gráfico 2 – Sazonalidade trimestral



Embora o padrão de sazonalidade não tenha sido alterado em relação ao período que antecede ao surto pandêmico, o agrupamento trimestral da tendência evidencia um constante aumento das vendas. Que de forma absoluta é possível verificar com o Gráfico 3, em que a cada ano os valores de vendas aumentaram de forma progressiva. Enquanto a relação percentual do aumento é discutida no Gráfico 4 e demonstra que a média de crescimento entre 2019 e 2018 foi de 6%, de 7% entre 2020 e 2019 e média de crescimento de 18% de 2021 em relação a 2020 o pico da série, finalizando com 11% de 2022 para 2021.

Gráfico 3 – Tendência trimestral






Gráfico 4 – Variação anual da tendência



4.3. Objetivo específico III: análise da influência da percepção de risco da pandemia da COVID-19 nas vendas chocolates no período


Esta seção tem como objetivo verificar as mudanças que ocorreram nas vendas de chocolates ao longo das acelerações e desacelerações da intensidade da pandemia da COVID-19 capturada pelos índices de pesquisas no Google relacionados à doença quanto ao número de casos registrados mês a mês. A relação entre interesse de pesquisa e número de casos é retratada pelo Gráfico 5 em que consta um movimento de oscilação cíclica do número de casos no Brasil. Segundo De Souza (2022), a pandemia de COVID-19 no Brasil ocorreu em ondas, com a primeira onda afetando a população de forma desigual e subsequentes ondas apresentando um aumento no número de casos relatados diariamente entre pessoas mais jovens de forma que a evolução da pandemia não foi homogênea e previsível em todo o país, com diferentes regiões experimentando diferentes padrões de disseminação da doença

Gráfico 5 – Interesse de pesquisa e nº de casos de COVID-19



Para compreender como os indicadores de agravamento ou desagravamento da pandemia se relacionam com as vendas de chocolates, o Gráfico 6 apresenta a aplicação do método de correlação cruzada entre os indicadores da pandemia e as vendas de chocolates no tempo. Essa análise permite evidenciar que o interesse de pesquisa assume valores negativos, positivos e zero em relação ao volume de vendas ao longo do período analisado, ou seja, para alguns meses o interesse de pesquisa variou na mesma direção das vendas em alguns meses e noutros não. Assim como o número de casos registrados que assume tanto valores negativos quanto positivos, que embora oscile entre os meses, assume valores em magnitude maior que o interesse de pesquisa tanto para valores negativos quanto positivos, indicando que o efeito do aumento do número de casos impactou o volume de vendas de chocolates em maior magnitude que os índices de interesse de pesquisa.

Gráfico 6 – Série temporal da correlação cruzada



Para uma análise mais detalhada sobre a relação dos indicadores de COVID-19 com o volume de vendas de chocolates, os períodos foram divididos entre semestres dos anos totalizando 6 períodos distintos e consta na Tabela 4. Vale destacar que valores negativos de correlação cruzada indicam que as vendas de chocolate e os indicadores da pandemia variaram em direções opostas no mês, enquanto valores positivos evidenciam a variação no mesmo sentido.

O primeiro semestre de 2020 apresentou o interesse de pesquisa negativo em relação às vendas para fevereiro, março e abril, ou seja, a maior quantidade de buscas por COVID-19 no Google ocorreu em concomitância com a redução das vendas, e neste semestre apenas junho apresentou correlação positiva sendo janeiro e maio valor zero. Avaliando-se o número de casos, observa-se um cenário igual para janeiro e maio com valores positivos para os demais meses, sendo que em junho o número de casos obteve uma correlação com vendas 98% maior que as buscas. O segundo semestre de 2020 apresentou correlação zero para ambos os indicadores da pandemia, exceto outubro em que o número de casos permaneceu com a correlação em maior magnitude que o interesse de pesquisa em 68%, com os dois positivos.

O ano de 2021 se inicia no primeiro semestre com janeiro apresentando correlação zero para os indicadores, sendo que em fevereiro os valores se tornam positivos com o número de casos apresentando correlação 105% maior que o interesse de pesquisa. Com

destaque para maio, que concerne à segunda onda da pandemia com o pico de casos do ano de 2021, em que a correlação também apresenta seu pico negativo. Ou seja, a elevação do número de casos nesse período ocorreu em contrapartida do volume de vendas. Já o segundo semestre apresenta os picos positivos da série, em agosto e outubro deste ano com o número de casos novamente apresentando magnitude maior de correlação do que o interesse de pesquisa capturado pelo Google Trends, que a partir de junho apresentou apenas valores positivos.

Por fim, o ano de 2022, no primeiro semestre em janeiro e fevereiro as buscas por COVID-19 apresentam valores negativos enquanto o número de casos é positivo, em março e abril ambos os sinais são positivos com maio e junho em direções opostas entre os indicadores, sendo que maio foi a primeira vez na série em que o interesse de buscas apresentou valores com magnitude maior de correlação que o número de casos em 15%. Adentrando-se o segundo semestre de 2022, julho segue a trajetória do mês anterior com o número de casos com correlação negativa e as buscas positiva, sendo que setembro, novembro e dezembro apresentam o mesmo comportamento que maio de 2021 com o interesse de pesquisa sendo maior que o número de casos em 2%, 7% e 31% respectivamente.

Tabela 4 - Correlação cruzada de Volume de vendas e COVID-19

Data	Semestre	Pesquisa Google Trends Volume de vendas	Nº casos de COVID-19 Volume de vendas
jan/20	2020 - S1	0	0
fev/20	2020 - S1	-0,0413	0,0579
mar/20	2020 - S1	-0,1252	0,0479
abr/20	2020 - S1	-0,0874	0,0098
mai/20	2020 - S1	0	0
jun/20	2020 - S1	0,0135	0,0267
jul/20	2020 - S2	0	0
ago/20	2020 - S2	0	0
set/20	2020 - S2	0	0
out/20	2020 - S2	0,0662	0,1071
nov/20	2020 - S2	0	0
dez/20	2020 - S2	0	0
jan/21	2021 - S1	0	0
fev/21	2021 - S1	0,0374	0,0765
mar/21	2021 - S1	0,0033	-0,0105
abr/21	2021 - S1	-0,0351	-0,165
mai/21	2021 - S1	-0,0261	-0,2796

Continua na próxima página

Conclusão da Tabela 4

Tabela 4 - Correlação cruzada de Volume de vendas e COVID-19

Data	Semestre	Pesquisa Google Trends Volume de vendas	Nº casos de COVID-19 Volume de vendas
set/21	2021 - S2	0	0
out/21	2021 - S2	0,051	0,1489
nov/21	2021 - S2	0,028	-0,0215
dez/21	2021 - S2	0,026	-0,1098
jan/22	2022 - S1	0,0248	-0,145
fev/22	2022 - S1	0,076	-0,0267
mar/22	2022 - S1	0,0775	0,0838
abr/22	2022 - S1	0,0659	0,056
mai/22	2022 - S1	0,0646	-0,0115
jun/22	2022 - S1	0,036	-0,0508
jul/22	2022 - S2	0,0263	-0,0132
ago/22	2022 - S2	0,0392	0,0509
set/22	2022 - S2	0,058	0,0569
out/22	2022 - S2	0,0509	0,0472
nov/22	2022 - S2	0,0357	0,0246
dez/22	2022 - S2	0,0279	-0,0025

Para uma melhor compreensão de como a pandemia afetou as vendas chocolates, os valores da correlação cruzada foram agrupados em 3 possibilidades, “Indiferente” quando o valor é zero, “Positivo” quando a variação do indicador segue na mesma direção das vendas ou “Negativo” quando a variação do indicador segue na direção oposta às vendas.

Em 2020, no primeiro semestre em 50% dos meses quanto maior a quantidade de pesquisas no Google sobre COVID-19, maiores as vendas de chocolate, enquanto no segundo semestre, 83% dos meses apresentaram correlação zero com as vendas. Para o número de casos, o primeiro semestre obteve 66% dos meses com correlação positiva, enquanto o segundo seguiu a trajetória do outro indicador com 83% dos meses com correlação zero.

Em 2021, no primeiro semestre 50% dos meses quanto maior a quantidade de pesquisas no Google sobre COVID-19, maiores as vendas de chocolate, seguindo-se o comportamento para o segundo semestre com 66% dos meses de correlação positiva. Já para o número de casos, o primeiro semestre de 2021 predominou a correlação positiva em 66% dos meses, já o segundo semestre não apresentou prevalência. Em 2022, tanto o primeiro

quanto o segundo semestre apresentaram 100% dos meses com correlação positiva para as pesquisas no Google sobre COVID-19. Enquanto o número de casos prevaleceu negativo no primeiro semestre com 66% dos meses e depois positivo com 66%. Como pode se observar na Tabela 5.

Tabela 5 - Distribuição da correlação cruzada por semestre

Data	Pesquisa Google Trends Volume de vendas			Nº casos de COVID-19 Volume de vendas		
	Indiferente	Positivo	Negativo	Indiferente	Positivo	Negativo
2020 - S1	33,3%	16,7%	50,0%	33,3%	66,7%	0,0%
2020 - S2	83,3%	16,7%	0,0%	83,3%	16,7%	0,0%
2021 - S1	16,7%	50,0%	33,3%	16,7%	16,7%	66,7%
2021 - S2	33,3%	66,7%	0,0%	33,3%	33,3%	33,3%
2022 - S1	0,0%	100,0%	0,0%	0,0%	33,3%	66,7%
2022 - S2	0,0%	100,0%	0,0%	0,0%	66,7%	33,3%

4.4. Objetivo Geral: efeito das estratégias de marketing adotadas ao longo da pandemia da COVID-19 nas vendas de chocolate

O objetivo desta seção concerne à avaliação do efeito das estratégias de marketing nas vendas de chocolates em perspectiva pré e durante a pandemia, para isso foram utilizadas técnicas de regressão de séries temporais com métodos de Machine Learning e interpretabilidade com Shap Value. Inicialmente foram realizados testes de normalidade das variáveis presentes na análise de série temporal com Machine Learning, sendo que estes testes têm o objetivo de determinar se um conjunto de dados tem distribuição normal ou não, como se apresenta na Tabela 6.

Tabela 6 - Teste de normalidade das variáveis utilizadas

Variáveis	Teste Shapiro		Teste Normal		Teste Qui-Quadrado		Teste KS	
	Estatística	p-valor	Estatística	p-valor	Estatística	p-valor	Estatística	p-valor
Preço Kg/R\$	0,81	0	35,7	0	1,55E+11	0	1	0
Investimento em Publicidade	0,8	0	37,6	0	2,29E+14	0	1	0
Investimento em Produto	0,91	0	19,71	0	1,65E+14	0	1	0
Incentivo por metas	0,97	0,28*	3,21	0,2*	3,37E+13	0	1	0

Continua na próxima página

Conclusão da Tabela 6

Tabela 6 - Teste de normalidade das variáveis utilizadas

Variáveis	Teste Shapiro		Teste Normal		Teste Qui-Quadrado		Teste KS	
	Estatística	p-valor	Estatística	p-valor	Estatística	p-valor	Estatística	p-valor
Volume de vendas (lag 24)	0,92	0	6,44	0,04*	8,79E+13	0	1	0
Média móvel de vendas (3m)	0,93	0	9,85	0,01*	1,91E+13	0	1	0
Mês	0,95	0,01*	11,32	0	9,45E+07	0	0,91	0
Captação líquida em poupança (R\$)	0,97	0,12*	6,08	0,05*	5,31E+15	0	0,54	0
Montante depositado em poupança (R\$)	0,82	0	162,49	0	6,84E+14	0	1	0
Taxa desocupação mercado de trabalho	0,94	0,01*	2,59	0,27*	1,52E+07	1*	1	0
Rendimento médio do mercado de trabalho	0,89	0	9,61	0,01*	4,30E+08	0	1	0
Índice IPCA	0,99	1*	0,03	0,99*	2,70E+07	1*	0,37	0
Atividade econômica do Comércio	0,95	0,02*	6,88	0,03*	4,21E+07	0,9*	1	0

Significância de 90%: ***; Significância de 95%: **; Significância de 99%: *


Os testes realizados foram construídos para rejeitar a hipótese nula quando a variável não possui distribuição normal, o que ocorre com valores de estatística abaixo de 0,01 (nível de significância de 99%). Para o teste Shapiro as variáveis que possuem distribuição normal estão: Incentivo por metas, Volume de vendas (lag 12), Captação líquida em poupança (R\$), Índice IPCA. Para o teste de normalidade as variáveis que possuem distribuição normal são: Incentivo por metas, Volume de vendas (lag 12), Captação líquida em poupança (R\$), Índice IPCA. Para o teste Qui-Quadrado as variáveis que possuem distribuição normal são apenas: Taxa de desocupação do mercado de trabalho, Índice IPCA, Atividade econômica do Comércio. De acordo com o teste KS, nenhuma das variáveis possui distribuição normal.

4.4.1. *Verificação de multicolinearidade*

De acordo com Hair et al. (1995) os valores de correlação indicativos de multicolinearidade seriam de magnitude superiores a 0,80, que não se observou no conjunto de dados utilizado. Para a presente pesquisa foi adotada uma das estratégias mais comuns para lidar com a multicolinearidade segundo Mcdaniel & Gates (1996), retirou-se quaisquer variáveis altamente correlacionadas na análise de modo que restaram apenas 15 utilizadas na modelagem. Modelos construídos sem uma verificação de multicolinearidade podem levar a uma análise de sistema errônea, em que além de acarretar problemas de interpretabilidade também pode causar instabilidade no modelo e este problema pode ser eliminado pela seleção de preditores apropriados do conjunto de dados. (GARG & TAI, 2013).

O teste de correlação de Pearson entre as variáveis evidenciou um valor máximo de correlação positiva entre as variáveis Montante depositado em poupança (R\$) e Preço Kg/R\$ do chocolate comercializado no valor de 0,71. Enquanto a o valor mais elevado de correlação negativa se deu entre as variáveis Mês e taxa de desocupação do mercado de trabalho no valor de -0,54 como pode se observar na Figura 4.

Figura 4 – Correlação de Pearson entre variáveis



4.4.2. Especificação do modelo

O modelo de Machine Learning XGBoost possui uma série de parâmetros personalizáveis para sua aplicação. Dentre as principais especificações utilizadas para o modelo desta dissertação estão:

- Tipo de modelo: regressor
- Base score: 0,5
- Booster escolhido: 'gbtree'
- Número de estimadores: 100
- Parâmetros de regularização: reg_lambda=1; reg_alpha=0; gamma=0; min_child_weight=1; subsample=1; colsample_bynode=1; colsample_bytree=1.

O modelo de regressão, neste caso, é utilizado para prever valores contínuos, uma abordagem distinta da utilizada em problemas de classificação que objetivam prever uma categoria ou classe (XGBOOST DEVELOPERS,2023). Para este modelo, o valor de previsão inicial, ou "Base score", atribuído a todos os casos é 0,5, que geralmente corresponde à média da variável alvo. O tipo de modelo escolhido, neste contexto, é 'gbtree', um dentre os diversos modelos suportados pelo XGBoost, que incluem árvores de decisão ('gbtree') e regressão linear ('gblinear', o 'gbtree' utiliza árvores de decisão, que são combinadas para criar um modelo mais forte (XGBOOST DEVELOPERS,2023). Neste modelo específico, um total de 100 dessas árvores de decisão foram combinadas para formar o modelo final, indicada no item da especificação chamado "Número de estimadores".

Os parâmetros de regularização são cuidadosamente ajustados para prevenir o *overfitting*, que é uma situação em que um modelo de machine learning se ajusta excessivamente aos dados de treinamento, prejudicando sua capacidade de generalizar para novos dados, e assim torná-lo mais robusto (XGBOOST DEVELOPERS,2023). Dentre eles, *reg_lambda* e *reg_alpha*, fixados em 1 e 0 respectivamente, atuam como parâmetros de regularização. O parâmetro *gamma*, aqui definido como 0, controla a redução mínima de perda necessária para efetuar uma divisão adicional em uma folha da árvore (XGBOOST DEVELOPERS,2023). Já o parâmetro *min_child_weight*, com valor 1, determina a soma mínima de pesos de todas as observações exigida em uma para cada nó da árvore de decisão (XGBOOST DEVELOPERS,2023). Por último, os parâmetros *subsample*, *colsample_bytree* e *colsample_bynode*, todos fixados em 1, controlam a subamostragem das observações e das colunas (variáveis), respectivamente. Valores menores que 1 indicariam subamostragem, enquanto um valor de 1 significa que todos os dados/variáveis são usados na construção de cada árvore (XGBOOST DEVELOPERS,2023).

4.4.3. *Resultados do modelo*

Com a utilização de 15 variáveis independentes obteve-se R^2 de 0,659. Como essa medida captura a porcentagem de variação total da variável dependente que é explicada pela variação das independentes com valor entre 0 e 1, isso significa que aproximadamente 66% das vendas de chocolates do período de teste são explicadas pelas variáveis independentes utilizadas. Ademais, o atingimento desse valor indica o atingimento do patamar de

aceitabilidade proposto por Ozili (2022) em que para valores de R^2 entre 0,50 e 0,99 tem-se que o modelo é aceitável para previsões em ciências sociais aplicadas. Além disso, os valores dos testes BIC em 236,42 e AIC de 235,149 sugerem que o modelo apresenta confiabilidade e estabilidade estatisticamente significativa para os resíduos. O teste Durbin-Watson de 1,114 indica que não há autocorrelação nos resíduos do modelo, conforme se observa na Tabela 7.

Tabela 7 - Resumo modelo de Machine Learning

<i>Modelo</i>	R^2	R^2 ajustado	BIC	AIC	Durbin-Watson
1	0,659	0,457	236,420	235,149	1,114


De acordo com Wooldridge (2005), o valor do R^2 em abordagens de regressão para ciências sociais aplicadas não são incomumente baixos, embora o R^2 encontrado nesta pesquisa seja uma indicação do potencial explanatório aceitável do modelo. Composto-se a compreensão da assertividade do modelo, o MAPE (Erro Percentual Absoluto Médio) obtido foi de 6,7% que indica que a média do erro da previsão é de 6,7%. Que de acordo com Lewis (1982, p. 40), valores de MAPE inferiores a 10% indicam “previsões altamente precisas”, para a faixa entre 10 e 20% “boas previsões” e valores de MAPE acima de 50% indicam “previsões imprecisas”. Já o valor do MAE (Erro Absoluto Médio) obtido foi de 237,34 que indica que em média o erro da previsão é de 237,34 tons, enquanto o RMSE (Raiz do Erro Quadrático Médio) ficou em 326,71 métrica esta que penaliza mais fortemente as previsões que estão mais distantes dos valores reais. Tais métricas de desempenho e assertividade do modelo podem ser verificadas na Tabela 8.

Tabela 8 - Assertividade modelo de Machine Learning

<i>Modelo</i>	MAE	RMSE	MAPE
1	237,34	326,71	6,7%

Para visualizar os resultados da previsão da série temporal de vendas de chocolates com método de Machine Learning o Gráfico 7 apresenta em cor azul os valores realizados das vendas de chocolate, enquanto a cor cinza evidencia a previsão realizada.

Gráfico 7 – Regressão com Machine Learning



Assim como indicado pela métrica MAPE no valor de 6,7%, verifica-se que a previsão construída com o modelo de Machine Learning é de fato altamente precisa ao longo do período de teste aproximando a curva de previsão aos valores realizados no período, com erro percentual absoluto médio de 6,7%.

4.4.4. Interpretabilidade do impacto das variáveis independentes nas vendas de chocolates

Em contraste com as abordagens de previsão tradicionais baseadas em regressão linear, que geram coeficientes Beta cognoscíveis - como evidenciado na Tabela 3 para o modelo de regressão OLS com as variáveis IPCA e atividade econômica - a interpretabilidade na abordagem de Machine Learning é feita de maneira diferente. Esta última utiliza o método SHAP para quantificar a contribuição de cada variável na previsão do modelo, assim o método SHAP fornece uma visão aprofundada do impacto das variáveis independentes (neste caso, nas vendas de chocolates - a variável dependente) de uma maneira absoluta e em termos de valores relativos, sejam eles positivos ou negativos. Essa metodologia foi utilizada conforme a abordagem proposta para modelos de Machine Learning por Ariza-Garzon et. al. (2020), Moncada-Torres et. al. (2021), e Arboleda-Florez & Castro-Zuluaga (2023).

Essa seção se divide em quatro etapas, a primeira trata da interpretabilidade do modelo em valores absolutos tanto para o treino, período entre 2018-05-01 e 2022-04-01, que contempla 85% das observações quanto para teste de 2022-05-01 a 2022-12-01 com 15 % do total de observações do período. A abordagem de treino e teste na construção de modelos de Machine Learning envolve a divisão do conjunto de dados em dois subconjuntos: um para treinar o modelo e outro para testá-lo. O treinamento permite ao modelo aprender a partir dos dados, enquanto o teste avalia a capacidade do modelo em fazer previsões precisas com novos dados. Esse método possibilita que o modelo possua uma boa capacidade de generalização e possa performar bem em dados não vistos anteriormente. De acordo com a abordagem exposta na seção 3.3.

A segunda parte aborda o valor normalizado do SHAP como percentual de explicabilidade do modelo de Machine Learning ao longo da série temporal, subdividindo-se em cada estratégia de marketing. A terceira parte apresenta a proporção das variáveis ao longo dos anos e permite analisar o modelo de forma global. Por fim, a quarta parte aprofunda na compreensão do efeito das estratégias de marketing no output do modelo de previsão de vendas.

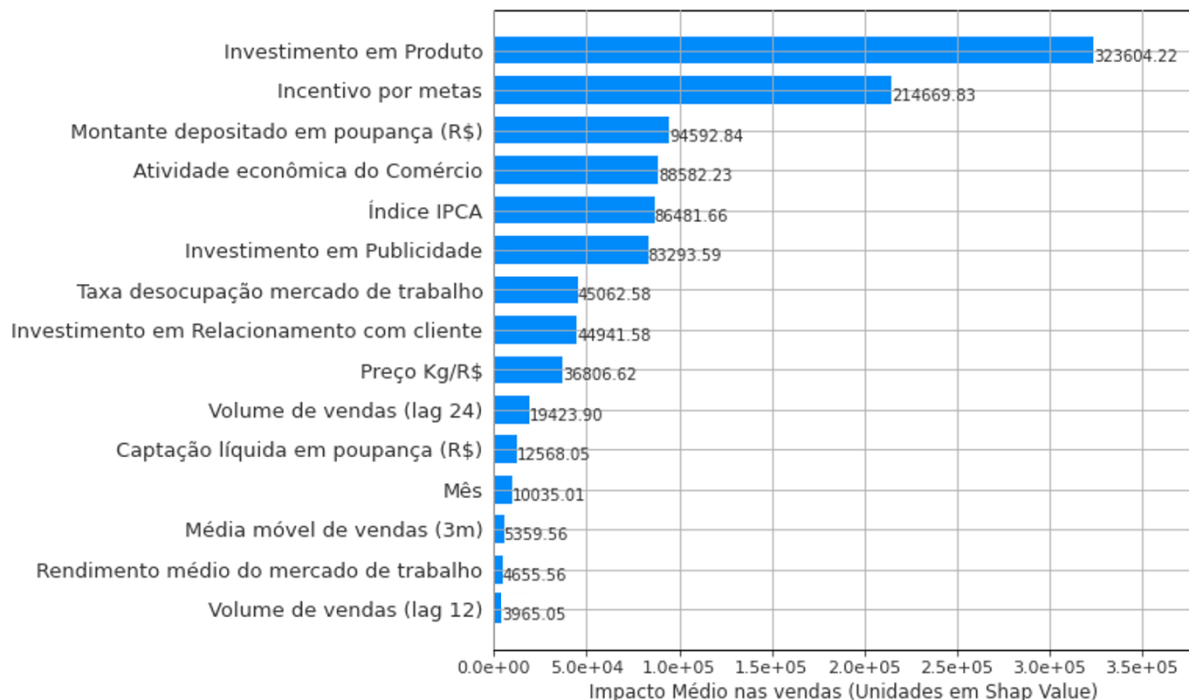
4.4.4.1. Interpretabilidade valores absolutos

O método SHAP proporcionou uma compreensão do modelo de regressão de séries temporais XGBoost, identificando que as variáveis "Investimento em Produto" e "Incentivo por Metas" como as principais determinantes do modelo, tanto no recorte de treino quanto de teste. Essa descoberta sugere que tais variáveis exercem um papel crucial na predição do desempenho do modelo, corroborando sua importância na análise e contribuindo para a compreensão dos fatores que afetam o fenômeno em estudo. A aplicação do método SHAP permitiu uma visão mais clara e intuitiva das relações entre as variáveis, auxiliando na interpretação e na justificativa das escolhas do modelo.

Especificamente sobre o período de treino, como pode se observar na Figura nº 5 as demais variáveis, como "montante de depósito em poupança", "atividade econômica do comércio", "índice IPCA" e "investimento em publicidade", embora não tenham se mostrado tão influentes quanto as duas primeiras, também apresentaram contribuições significativas para o modelo. A variável de poupança ocupou o terceiro lugar em termos de relevância para as previsões, que sugere que a quantidade de dinheiro em circulação na economia impacta as

vendas de chocolates. Seguida da "atividade econômica do comércio" indicando que o contexto econômico pode afetar as vendas no período. O "índice IPCA" ocupa o quinto lugar em termos de contribuição para a previsão das vendas, evidenciou uma correlação entre o nível de preços de mercado e as vendas de chocolates. Por fim, o "investimento em publicidade" mostrou-se relevante, mas com um impacto menos expressivo que as variáveis principais, sugerindo que, apesar de sua contribuição, outras estratégias podem ser mais eficazes para impulsionar o desempenho do modelo. Essas constatações ampliam a compreensão do fenômeno estudado, destacando a relevância de considerar um conjunto diversificado de variáveis na construção de modelos preditivos.

Figura 5 – Shap Value treino – Valores absolutos

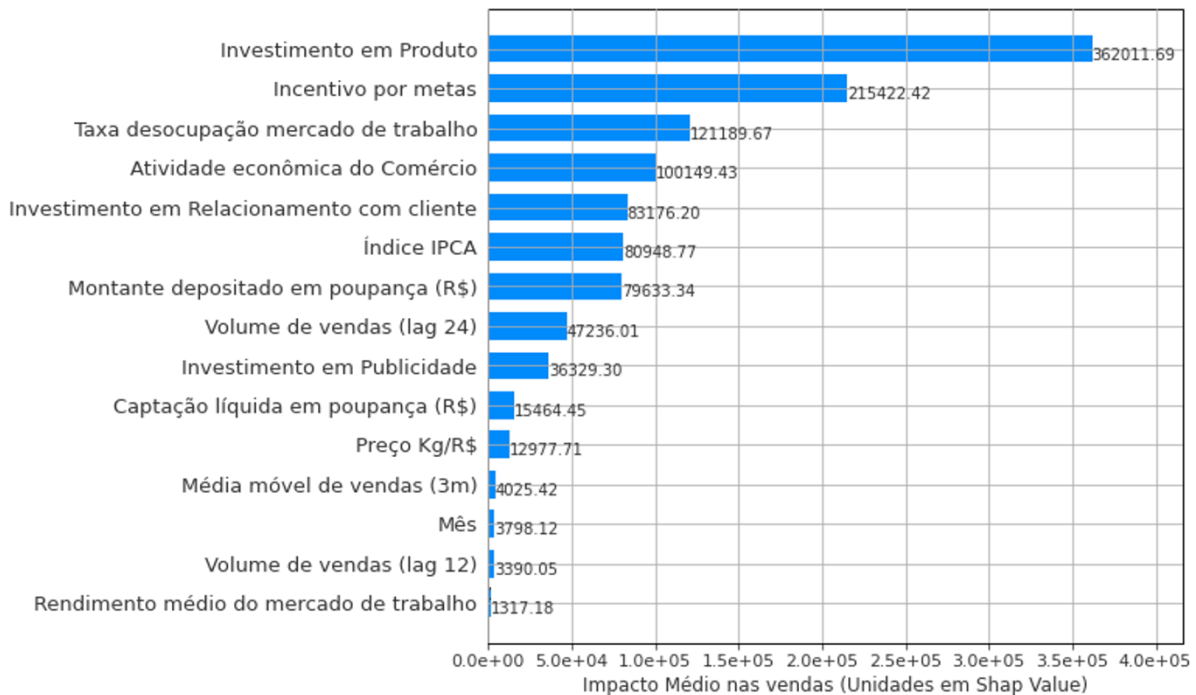


Para o período de teste, as duas principais variáveis permanecem as mesmas "Investimento em Produto" e "Incentivo por Metas", mas as demais variáveis apresentaram diferenças significativas em relação ao período de treino. A "taxa de desocupação do mercado de trabalho" emergiu como um fator preponderante, em terceira posição, indicando a possível relação entre nível de emprego na economia e o consumo de chocolates. Em seguida, a "atividade econômica do comércio" manteve sua importância, reforçando a influência do contexto econômico nas vendas do produto. Notavelmente, o "investimento em relacionamento com cliente" ascendeu da oitava posição no período de treino para uma

posição de maior destaque no período de teste, sugerindo que as estratégias voltadas para o relacionamento com o cliente podem ter se tornado mais relevantes ao longo do tempo.

Outra diferença observada foi o posicionamento do "índice IPCA" no período de teste, que também demonstrou relevância para as vendas de chocolates. Essas mudanças nas variáveis mais influentes em comparação com o período de treino destacam a importância de adaptar e atualizar os modelos de previsão, levando em consideração as mudanças no cenário e nas dinâmicas de mercado. A comparação entre os períodos de treino e teste evidencia a complexidade e a evolução dos fatores que influenciam as vendas de chocolates, ressaltando a importância de uma abordagem analítica robusta e adaptativa e longitudinal. Como pode se evidenciar com a Figura 6.

Figura 6 – Shap Value teste – Valores absolutos




4.4.4.2. Valores normalizados

Para além da comparação da magnitude do impacto das variáveis independentes por meio das unidades SHAP de contribuição, os efeitos das variáveis foram normalizados em termos proporcionais, de 0 a 100%. Sendo possível analisar o impacto relativo de cada variável em ao longo do tempo. Essa abordagem permite uma comparação mais precisa e informativa dos efeitos das variáveis, facilitando a identificação das variáveis mais relevantes e suas contribuições distintas ao longo da série temporal.

Com o objetivo de avaliar o efeito que as estratégias de marketing adotadas ao longo da pandemia da Covid-19 tiveram nas vendas de chocolate, o Gráfico 9 apresenta a contribuição das variáveis em termos proporcionais ano a ano, com destaque para as variáveis de estratégias de marketing.

Gráfico 8 – Efeito das estratégias entre anos



É possível observar que as estratégias de marketing apresentaram contribuição de 50% nas vendas de chocolates em todos os anos analisados, enquanto as demais variáveis tomadas em conjunto tiveram máximo de 42,7 % de impacto nas vendas. Abaixo estão em detalhe o impacto de cada estratégia de marketing adotada.

As estratégias de marketing analisadas demonstraram uma contribuição significativa nas vendas de chocolates, com um impacto superior a 50% em todos os anos estudados. Com destaque para incentivo por metas e investimento em produto como estratégias mais relevantes, sendo Investimento em relacionamento com cliente e investimento em publicidade as estratégias que se observa um menor impacto, os resultados detalhados dessas estratégias e suas contribuições ao longo dos anos podem ser observados de maneira estruturada na Tabela 9.

Tabela 9 - Efeito normalizado das estratégias na venda de chocolates

	2018	2019	2020	2021	2022
<i>Variável</i>	<i>(%)</i>				
Investimento em Relacionamento com cliente	5,42	5,39	2,73	4,30	5,52
Incentivo por metas	22,33	15,07	30,06	16,10	15,74
Investimento em Produto	22,49	30,63	26,36	35,62	33,94
Investimento em Publicidade	7,08	8,00	6,55	11,07	3,27
Demais variáveis	42,67	40,92	34,30	32,91	41,53

No período de mudança, que corresponde à transição da normalidade pré-pandemia para a vigência inicial da emergência sanitária em 2020, a estratégia que apresentou a maior contribuição nas vendas foi o "Incentivo por metas", com um efeito normalizado de 30,06%. Em contraste, a estratégia de "Investimento em Relacionamento com cliente" foi a que menos contribuiu, com um valor de 2,73%. No período de crise, durante o agravamento severo da pandemia em 2021, o "Investimento em Produto" assumiu a liderança, representando 35,62% do impacto nas vendas. A estratégia de "Investimento em Relacionamento com cliente" novamente apresentou a menor contribuição, com 4,30%. Nos períodos de normalidade, compreendidos pelos anos sem pandemia de 2018, 2019 e 2022, a estratégia de "Investimento em Produto" demonstrou consistentemente a maior contribuição, com valores respectivos de 22,49%, 30,63% e 33,94%. A estratégia de "Investimento em Publicidade" mostrou-se menos impactante nesses anos, contribuindo com 7,08%, 8,00% e 3,27% respectivamente.

4.4.4.2.1. Investimento em relacionamento com cliente

As ações de Relacionamento com Cliente, que incluem renovação de lojas, propaganda compartilhada, eventos promocionais em datas comemorativas e treinamento de representantes comerciais, tiveram um impacto constante antes da pandemia, representando 5,4% das vendas em 2018 e 2019. Com a chegada da pandemia em 2020, contudo, seu impacto decaiu para 2,7% em meio às mudanças necessárias na estratégia, como o aumento do treinamento digital e a participação em redes sociais.

No auge da pandemia em 2021, a estratégia conseguiu uma recuperação parcial, voltando a representar 4,3% das vendas. Isso foi possivelmente impulsionado pelas soluções personalizadas e promoções especiais, mencionadas por Zhang et al. (2019) como capazes de alavancar as vendas de forma temporária.

Com a normalidade retornando em 2022, a contribuição dessa estratégia voltou ao patamar pré-pandemia, com 5,5% das vendas. Embora tenha se mantido positiva ao longo dos anos, as evidências encontradas sugerem que em períodos de grandes mudanças ou crises, como o que foi causado pela pandemia, o Relacionamento com Cliente não seja a principal forma de investimento para alavancar vendas.

4.4.4.2.2. Incentivo por metas

O incentivo de metas, que é um investimento realizado de forma de desconto para o ponto de venda quando este atinge uma meta pré-estabelecida, demonstrou influência expressiva nos resultados da empresa, sendo especialmente efetivo no período de normalidade pré-pandemia, contribuindo com 22,3% e 15,1% para as vendas em 2018 e 2019, respectivamente.

O destaque, no entanto, se apresentou em 2020, durante a eclosão da pandemia e o consequente período de mudança. Nesse ano, a estratégia alcançou um pico histórico de 30,1%, contribuindo com expressivos 30,1% para as vendas. Tal feito realça a eficácia dessa abordagem durante períodos críticos, e vai ao encontro da diretriz de Jiang et al. (2015), que aponta a otimização conjunta da promoção de preços e recomendação de produtos como a melhor maneira de influenciar a decisão de compra dos clientes.

Após o pico, a contribuição do incentivo por metas para as vendas estabilizou-se em 16,1% e 15,7% nos anos de 2021 e 2022, respectivamente, consolidando-se assim como a segunda variável mais relevante nos anos analisados, mesmo diante do agravamento da pandemia em 2021 e a volta da normalidade em 2022. As evidências encontradas sugerem que em períodos de grandes mudanças a estratégia de incentivo por metas seja a principal estratégia de marketing para alavancar vendas.

4.4.4.2.3. Investimento em produto

A estratégia de investimento em produto exibiu uma contribuição significativa nos resultados no período, com valores superiores a 20% em todos os anos. Em 2018, o investimento em produto apresentou uma contribuição de 22,49%, seguido por um aumento expressivo para 30,63% em 2019. Mesmo durante a pandemia, em 2020, essa variável manteve um impacto considerável, com uma contribuição de 26,36%. Nos anos seguintes, o investimento em produto continuou a desempenhar um papel crucial, com uma contribuição

comparável ao período pré-pandemia em 2019 em 2021 35,62% e de 33,94% em 2022. Esses dados evidenciam a relevância dessa estratégia de investimento como a mais significativa dentre as analisadas

O investimento em produto, que consiste majoritariamente na aplicação de recursos para aprimorar a visibilidade do produto no ponto de venda, revelou-se crucial para a empresa em todos os períodos analisados, com contribuições superiores a 20% anualmente. Em 2018, essa estratégia apresentou um índice de 22,49%, que saltou para 30,63% em 2019, durante o período de normalidade pré-pandemia.

No período de grande mudança, em 2020, a estratégia de investimento em produto manteve sua relevância, com contribuição de 26,36% para as vendas. Esse resultado demonstra a resiliência da estratégia durante um período crítico, comprovando as considerações de Habib (2011) sobre a importância das previsões no planejamento e na tomada de decisões em gestão de cadeias de fornecimento.

No período de crise em 2021, o investimento em produto atingiu sua máxima histórica em 35,62%, seguido da retomada da normalidade em 2022, com contribuição 33,94% nas vendas. Estes dados corroboram a eficácia da estratégia e sua consonância com as práticas de inovação em produto, que incluem a tomada de decisão baseada em big data, utilização de Machine Learning e algoritmos de recomendação, conforme apontado por Betru et al., (2017) e Hu et al., (2015). As evidências encontradas sugerem que o investimento em produto se destaca como a estratégia de investimento mais significativa dentre as analisadas, independente das circunstâncias de crise, mudança ou normalidade, com o diferencial de que em momentos de crise esta estratégia seja a mais profícua para alavancagem de vendas.

4.4.4.2.4. Investimento em publicidade

A estratégia de investimento em publicidade demonstrou-se como a segunda variável menos notável para alavancagem de vendas na visão geral entre os períodos, na especificidade de período de normalidade pré-pandemia, 2018 e 2019, a contribuição do investimento em publicidade para as vendas foi de 7,08% e 8%, respectivamente. No entanto, durante o período de mudança em 2020, com a emergência da pandemia, a contribuição dessa estratégia caiu para 6,55%, apesar das mudanças adaptativas mencionadas pelos entrevistados, como a realocação de recursos para mídias digitais.

Surpreendentemente, no período de crise em 2021, a estratégia de investimento em publicidade atingiu um pico de 11,07%, o que pode ser atribuído à ênfase na mídia digital durante a pandemia e às práticas de otimização de gastos, em linha com as diretrizes de Roberts (2003). Entretanto, no período de normalidade pós pandêmico em 2022, a contribuição caiu drasticamente para 3,27%, para o menor valor registrado, evidenciando um potencial limitante dessa estratégia em tempos de estabilidade.

Esse contexto vai ao encontro das tendências observadas na indústria do varejo, que experimentou uma significativa transformação digital (HAGBERG et al., 2015), bem como das práticas de eficiência e reestruturação em períodos de crise (ROBERTS, 2003). Mesmo com a adaptação à nova realidade, o investimento em publicidade não se mostrou tão eficaz quanto o investimento em produto, indicando que, embora essencial, a publicidade pode ser menos determinante para as vendas em situações de normalidade e crise.

4.4.4.3. Interpretabilidade valores Relativos

Ao adentrar à próxima seção da pesquisa, uma avaliação metódica e comparativa da contribuição das estratégias de marketing na geração de vendas de chocolates será conduzida, com a perspectiva de contraste do seu efeito com o valor percentual investido em cada estratégia. Esta análise permitirá discernir relações entre o investimento em marketing e o consequente impacto nas vendas de chocolates. É relevante esclarecer que os valores absolutos não foram empregados nesta fase da pesquisa, como decisão estratégica da empresa de não divulgar os montantes específicos investidos em cada estratégia de marketing. Tal abordagem preserva a confidencialidade dos dados financeiros da organização, ao mesmo tempo que permite a realização de uma análise comparativa robusta com base em valores percentuais. Esta metodologia, portanto, mantém a integridade dos insights gerados, enquanto respeita a privacidade financeira da empresa em questão.


4.4.4.3.1. Publicidade

Os dados presentes no Gráfico 9 indicam que o investimento em publicidade tende a atingir picos de representatividade percentual durante os meses de abril a junho. Notavelmente, em 2018, esses investimentos representaram entre 50% e 60% do total; em 2019, quase 90% do total de investimentos foram concentrados em abril. Durante o período da pandemia, o padrão de investimento se manteve nos mesmos meses, representando 40%

do total em abril de 2020 e 2021. No entanto, para 2020, há um indicativo de nova trajetória de investimento.

Curiosamente, a análise dos dados revela que valores percentuais mais altos de investimento em marketing não necessariamente se traduzem em efeitos superiores nas vendas. Isso é evidenciado ao se observar os segundos semestres de 2018 e 2019, assim como o ano de 2022. Apesar de a publicidade ter representado entre 50% e 60% dos investimentos realizados em junho de 2018, ao longo do segundo semestre de 2018, foi atingido um máximo de contribuição nas vendas na faixa de apenas 10 a 20%. Esses achados ressaltam a complexidade intrínseca da correlação entre o investimento em marketing e as vendas, na mesma direção dos anos pré pandemia está o ano 2022, quando, apesar do aumento percentual do investimento ocorrer de maio a setembro, variando no intervalo de 20 a 50% do total de investimentos, o impacto nas vendas manteve-se estável, não ultrapassando a marca de 10%. Esta constatação reforça que incrementos percentuais no investimento em marketing não garantem, necessariamente, um aumento proporcional nas vendas, evidenciando a necessidade de estratégias de marketing mais eficazes e aprofundamento na análise dos fatores que influenciam esta relação.

Gráfico 9 – Efeito das estratégias relativo ao valor investido (Publicidade)



4.4.4.3.2. Produto


Avançando para o tópico do investimento em produto, verifica-se com a análise do Gráfico 10 uma dinâmica de investimento distinta daquela observada na publicidade. Em 2018, o pico de investimento em produto foi registrado em outubro, situando-se na faixa de 60 a 70%. No ano seguinte, 2019, o valor mais alto foi alcançado em maio, na faixa de 70% a 80%. Contudo, com o advento da pandemia em 2020, os valores de investimento em produto passaram a oscilar numa ampla faixa que vai de 40% a 50% até 90%. Notavelmente, os investimentos giraram abaixo desse patamar em apenas duas ocasiões durante 2022, especificamente nos meses de julho e outubro, quando se situam na faixa de 30 a 40%.

Ao analisar a relação entre o investimento em produto e as vendas, observa-se que, em junho e julho de 2018, o efeito do investimento em produto nas vendas foi inferior a 10%. No entanto, no segundo semestre de 2018, este valor oscilou entre 10 e 40%, indicando uma correlação variável entre o investimento em produto e seu impacto subsequente nas vendas.

Um fenômeno notável ocorreu em dezembro de 2018, quando houve um aumento do investimento em produto, subindo de 40% para a faixa de 50% a 60%. Embora esse investimento tenha caído para a faixa de 40% a 50% em janeiro de 2019, o efeito nas vendas alcançou a faixa de 60% no mesmo mês. Este fenômeno foi observado novamente com o investimento realizado em fevereiro de 2021, cujo impacto parece ter se manifestado em março, migrando de um investimento de 30% a 40% em fevereiro para um efeito de 50% a 60% em abril. Isso sugere que o efeito do investimento pode não ocorrer imediatamente, mas sim com um atraso de um a dois meses.

A análise dos dados de setembro de 2021 também evidencia essa possível defasagem, com um aumento observável no efeito em novembro de 2021. No entanto, esse padrão não se manteve no ano de 2022. Apesar de terem sido realizados investimentos na casa de 70% a 80% do total nos meses de março a maio, o efeito nas vendas não ultrapassou a faixa de 40% a 50% no mês do investimento ou nos meses subsequentes. Isso enfatiza ainda mais a complexidade e a natureza multifatorial da relação entre investimento em marketing e vendas.

Gráfico 10 – Efeito das estratégias relativo ao valor investido (Produto)



4.4.4.3.3. Incentivo por metas


O efeito do incentivo de metas na venda de chocolates apresenta uma trajetória caracterizada por ampla variabilidade, oscilando entre a faixa de 10% e a faixa de 50% a 60% da contribuição total. Notavelmente, a proporção do investimento em incentivo de metas não ultrapassou a faixa de 40% do total de investimentos. Durante o período pré-pandêmico, os investimentos mais altos em incentivo de metas não necessariamente se traduziram em contribuições proporcionais para as vendas no mesmo período. Por exemplo, em julho de 2018, o investimento situava-se entre 30 e 40%, porém o efeito nas vendas foi apenas de 10% a 20%. O mesmo ocorreu em janeiro de 2019, quando um investimento entre 30 e 40% resultou em um impacto de apenas 10% nas vendas. Como se observa no Gráfico 11.

Com o advento da pandemia em 2020, observou-se uma maior congruência entre a proporção do investimento em incentivo de metas e seu impacto nas vendas. Durante os meses de julho, agosto e setembro, o investimento ficou na faixa de 20% a 30%, correspondendo de forma mais próxima ao efeito nas vendas. Este alinhamento continuou em 2021, quando os valores de investimento e o efeito correspondente nas vendas, durante os meses de julho a novembro, apresentaram-se nas faixas de 10 a 20%.

Entretanto, 2022 trouxe um fenômeno intrigante. A maior parte do ano manteve-se na faixa de 10% a 20% para ambas as variáveis, com exceção de maio, quando um investimento

na faixa inferior (até 10%) resultou numa contribuição expressiva para as vendas, na faixa de 50% a 60%. Este fenómeno não foi isolado e pôde ser observado em outras ocasiões, como em abril de 2020, abril de 2019, fevereiro de 2021 e agosto de 2022. Esses dados sugerem que uma redução na proporção do valor investido na forma de incentivo de metas para a faixa de até 10% do total pode ser uma estratégia eficaz para otimização do o impacto nas vendas, principalmente no período de normalidade pós pandemia.

Gráfico 11 – Efeito das estratégias relativo ao valor investido (Metas)



4.4.4.3.4. Relacionamento

O investimento em relacionamento com clientes atingiu o seu pico em janeiro de 2019, ocupando uma faixa de 25 a 30% do orçamento total de marketing. No entanto, o impacto máximo desse tipo de investimento nas vendas ocorreu posteriormente, em maio de 2021, contribuindo com 25% do total de vendas daquele mês. No período pré-pandêmico, os investimentos nessa estratégia de marketing geralmente representavam até 15% do total. Com a eclosão da pandemia, houve uma redução desses investimentos, cujos valores máximos não ultrapassam 5% do total investido. As exceções ocorreram em maio e outubro de 2020 e janeiro de 2022, quando os valores se situam na faixa de 5% a 10%.


O impacto do investimento em relacionamento com clientes nas vendas mostrou-se bastante variável. Em 2020, oscilou entre as faixas de 5 a 15%, enquanto em 2019 atingiu seus picos em maio e agosto, com faixas respectivamente de 10 a 15% e 15 a 20%. Vale

ressaltar que, em agosto de 2019, a proporção do investimento foi inferior a 2% do total, no entanto, o impacto nas vendas foi significativo, situando-se na faixa de 15 a 20%. Isso indica que um decréscimo acentuado no investimento proporcional pode resultar em um grande impacto positivo nas vendas.

Este fenômeno foi novamente observado em maio de 2021, quando um investimento próximo a zero resultou em um impacto máximo nas vendas, situando-se na faixa de 20% a 25%. No segundo semestre de 2022, os investimentos em relacionamento com clientes permaneceram até 5% do total, com um efeito que variou entre 5% e 15% até novembro.

Considerando todas as estratégias de marketing examinadas, é possível identificar padrões distintos de investimento e impacto nas vendas. As estratégias de publicidade e produto, embora tenham recebido proporções maiores de investimento, não garantiram necessariamente um impacto proporcionalmente maior nas vendas. Por outro lado, o incentivo de metas e o relacionamento com clientes, embora tenham recebido uma proporção menor do investimento total, apresentaram momentos de alto impacto nas vendas. Essas observações destacam a complexidade da relação entre investimento em marketing e vendas e a importância de uma abordagem estratégica e multifacetada para maximizar a eficácia do marketing. Como se observa no Gráfico 12.

Gráfico 12 – Efeito das estratégias relativo ao valor investido (Relacionamento)



5. CONCLUSÃO

Esta seção apresenta as conclusões da presente dissertação e está organizada em duas partes principais. A primeira mostra as conclusões finais da dissertação e evidencia o atingimento dos objetivos específicos e geral, além da confirmação ou não das hipóteses e oferece um panorama entre contribuições para literatura e para boas práticas gerenciais no mercado estudado. A segunda parte conta com a deliberação sobre as limitações do estudo e sugestão de estudos futuros.

5.1. Conclusões finais da dissertação

Esta dissertação buscou investigar como objetivo geral o efeito que as estratégias de marketing adotadas ao longo da pandemia da Covid-19 nas vendas de chocolate de uma empresa que atua no mercado brasileiro. Para isso, elaborou-se três objetivos específicos que foram construídos como etapas necessárias para alcançar o objetivo geral

Os resultados obtidos nesta pesquisa atendem ao objetivo específico I, que propunha identificar quais foram as estratégias de marketing utilizadas pela empresa estudada no mercado de Chocolates ao longo da crise de COVID-19. A pesquisa em profundidade permitiu compreender as estratégias utilizadas pela empresa do setor de chocolates, elucidando a transição do marketing tradicional para o digital, o investimento em visibilidade do produto, o incentivo através de metas e a importância do relacionamento com o cliente. As contribuições suscitadas por essa etapa da pesquisa proporcionam contribuições sobre boas práticas gerenciais, ao evidenciar quais foram as estratégias adotadas para sobrevivência e sucesso adotadas pela empresa em meio a uma crise inédita, reforçando a necessidade de ser ágil e adaptável, reorientando investimentos de mídias tradicionais para digitais, e reconhecendo a importância de manter uma oferta constante de produtos apesar dos desafios logísticos.

Com base nos resultados obtidos com o objetivo específico II da pesquisa, que se propunha analisar as mudanças que ocorreram nas vendas de chocolates ao longo do período da pandemia da COVID-19, foi atingido. Foi identificada uma alteração consistente nas vendas a partir de novembro de 2020, embora a tendência geral de vendas tenha permanecido positiva, contradizendo parcialmente a hipótese 4. Além disso, a sazonalidade das vendas se

manteve desde 2018, concentrada no quarto trimestre do ano, confirmando a Hipótese 5 de que a pandemia não alterou o padrão sazonal de vendas de chocolates. Assim, as evidências encontradas permitiram um entendimento mais aprofundado do impacto da pandemia nas vendas de chocolates.

Os resultados obtidos com o objetivo específico III deste estudo proporcionam uma contribuição importante para a literatura, apresentando uma análise detalhada das vendas de chocolates durante o período da pandemia da COVID-19. Visto que demonstra como a pandemia tem influenciado os padrões de consumo conforme indicado por DI CROSTA et. al (2021) e Mahmud et. al (2021). A pesquisa também expande a compreensão sobre a influência de eventos globais disruptivos nas vendas de produtos específicos, neste caso, chocolates, oferecendo um panorama sobre a flutuação nas tendências de vendas e padrões sazonais durante um período de crise de saúde global.

Os resultados obtidos com o objetivo específico III deste estudo proporcionam uma contribuição sobre boas práticas gerenciais ao oferecer insights sobre como os gerentes do setor podem utilizar estas informações para entender melhor como eventos globais, como uma pandemia, podem afetar as vendas e os padrões de consumo. A identificação de uma tendência positiva de vendas durante a pandemia, apesar de oscilações, sugere que a demanda por chocolates pode ser resiliente mesmo em tempos de crise. Além disso, a manutenção do padrão sazonal das vendas sugere que os esforços de marketing e vendas devem continuar a focar no quarto trimestre do ano. Com base nisso, as práticas de gestão devem, portanto, incorporar esses aprendizados para desenvolver estratégias resilientes e eficazes em face de futuros desafios globais.

Os resultados da pesquisa respondem ao objetivo específico III, conforme indicado pelos dados, houve momentos em que os índices de COVID-19 e as vendas de chocolates variaram na mesma direção, enquanto em outros momentos eles variaram em direções opostas, assim como confirmam a hipótese de que as vendas de chocolates foram influenciadas pelas variações dos índices associados à COVID-19.

Os resultados da pesquisa que respondem ao objetivo específico III proporcionam uma contribuição para a literatura ao explorar a interação entre a percepção de risco da pandemia COVID-19 e o comportamento do consumidor no contexto específico da indústria de chocolates. Por exemplo, a análise revelou que o segundo semestre de 2020 foi um período

de indiferença, com uma correlação zero entre os indicadores da pandemia e as vendas de chocolates. Contudo, nos semestres restantes, verificou-se uma variação substancial, como no primeiro semestre de 2021, em que os casos de COVID-19 e as vendas de chocolates variaram em direções opostas em 66,7% do tempo. Essa correlação foi ainda mais pronunciada em maio de 2021, quando ocorreu a segunda onda da pandemia, atingindo um pico negativo em correlação. Além disso, também destaca a importância do uso de ferramentas digitais, como o Google Trends, na previsão e monitoramento do comportamento do consumidor em tempos incertos.

Os resultados da pesquisa que respondem ao objetivo específico III proporcionam uma contribuição às boas práticas gerenciais ao evidenciar que os gestores devem ser ágeis e flexíveis para adaptar suas estratégias de vendas e marketing em resposta a flutuações dos indicadores de agravamento da condição de crise. Ademais, ao constatar que a percepção de risco pode influenciar o comportamento do consumidor, os gestores podem considerar maneiras de posicionamento de mercado que se proponha a minimizar a percepção de risco do consumidor, no caso da pandemia de COVID-19 através de práticas de higiene reforçada ou ofertas de entrega segura.

No que tange ao atingimento do objetivo geral da pesquisa, com base nos resultados apresentados, este foi amplamente atingido. A investigação visava compreender a relação entre diferentes estratégias de marketing e suas respectivas contribuições para as vendas de chocolates. Os dados revelaram que o investimento proporcional em marketing, embora significativo, não garantiu, necessariamente, um impacto correspondente nas vendas. Esse fenômeno foi observado com as estratégias de publicidade e produto, que, apesar de receberem a maior parte dos investimentos, não resultaram consistentemente em vendas proporcionais. Por outro lado, estratégias como incentivo de metas e relacionamento com clientes, que receberam investimentos proporcionalmente menores, em certos momentos proporcionaram um impacto significativo nas vendas. Notavelmente, houve ocasiões em que um investimento reduzido em incentivo de metas ou relacionamento com clientes resultou em contribuições expressivas para as vendas.

Ademais, ao avaliar o efeito dos indicadores econômicos brasileiros nas vendas de chocolate, as evidências indicaram que tanto o desempenho da atividade econômica do comércio, quanto a inflação, quanto a taxa de desocupação tiveram um impacto significativo nas vendas de chocolate. Portanto, a hipótese de que essas variáveis econômicas influenciam

significativamente as vendas de chocolate foi confirmada, permitindo uma maior compreensão das dinâmicas de mercado e oferecendo orientações estratégicas valiosas para a empresa

Esses achados confirmam a hipótese inicial de que a relação entre o investimento em marketing e o impacto nas vendas é complexa e multifatorial, e não necessariamente proporcional. Consequentemente, os resultados enfatizam a necessidade de uma abordagem estratégica e diversificada ao investir em marketing, uma vez que diferentes estratégias podem ter impactos variados nas vendas em diferentes momentos e contextos. Além de trazer contribuições para a literatura existente sobre indicadores econômicos brasileiros como inflação, taxa de desocupação e as vendas de produtos em setores específicos, neste caso, o setor de chocolates. Pois reforça a ideia de que o ambiente econômico tem um impacto significativo nas vendas de produtos, corroborando com os trabalhos anteriores (CHOI, 2003; LEE et. al, 2012; QUELCH & JOCZ, 2009). Haja visto que este estudo também contribui para o entendimento de como a pandemia COVID-19 afetou a economia em geral, e o setor de chocolates, em particular, por meio de seus impactos sobre a atividade econômica, a inflação e a taxa de desocupação. Isso amplia a literatura existente sobre os efeitos econômicos da pandemia em setores específicos, fornecendo um exemplo detalhado de sua influência sobre as vendas de produtos de consumo.

Este estudo apresenta contribuições para a literatura na área de estratégia de marketing, especialmente no contexto de mudanças de mercado abruptas e imprevistas, como uma pandemia global. Primeiro, fornece evidências empíricas de como diferentes estratégias de marketing - investimento em relacionamento com o cliente, incentivo por metas, investimento em produto e investimento em publicidade - impactaram as vendas de uma empresa de chocolates no mercado brasileiro durante um período de cinco anos que englobou condições de normalidade, mudança e crise. Essas descobertas expandem a compreensão do papel crítico das estratégias de marketing durante eventos disruptivos, demonstrando não só a sua relevância geral, mas também a eficácia relativa de diferentes estratégias em contextos distintos. Além disso, o estudo reforça a importância da flexibilidade estratégica, destacando como as empresas podem se adaptar em tempos de crise alterando o foco de suas estratégias de marketing.

Os resultados do estudo podem orientar as práticas gerenciais na direção que a efetividade de diferentes estratégias depende do contexto. Por exemplo, o "incentivo por metas" mostrou ser particularmente eficaz durante a transição para a pandemia, enquanto o "investimento em produto" foi mais eficaz durante o pico da crise e na retomada da normalidade. Essas observações sublinham a necessidade de um gerenciamento estratégico ágil que possa responder eficazmente às mudanças nas condições do mercado. Além de contribuir para boas práticas gerenciais ao sugerir que ao acompanhar as taxas de desocupação, inflação e o desempenho da atividade econômica, a empresa pode ajustar suas estratégias de vendas e marketing para maximizar o potencial de vendas em diferentes condições econômicas. Por exemplo, em tempos de baixa taxa de desocupação, as vendas de chocolate podem ser estimuladas através de campanhas de marketing mais agressivas. Além disso, as alterações na inflação e no desempenho econômico podem exigir a adoção de estratégias de precificação dinâmicas para maximizar as vendas e as margens de lucro. Estas práticas são vitais para manter a resiliência do negócio em face de mudanças no ambiente econômico e podem fornecer um modelo para outras empresas em setores semelhantes.

Os resultados obtidos permitiram alcançar todos os objetivos propostos respondendo à questão de pesquisa deste trabalho: qual é o impacto das estratégias de marketing adotadas por uma empresa que atua no mercado brasileiro nas vendas de chocolates ao longo da pandemia da COVID-19. As hipóteses relativas aos objetivos definidos para esta tese também foram verificadas. As hipóteses e o resultado da sua análise são indicados no Quadro 3. Um detalhamento dos resultados da análise das hipóteses e a apresentação das contribuições teóricas e práticas do presente estudo são desenvolvidos após o quadro.

Quadro 3 - Decisão para hipóteses da dissertação

Hipóteses	Decisão
H1: as estratégias de marketing utilizadas pela empresa influenciaram as vendas de chocolate no período	Cofirmada
H2: estratégias de marketing tiveram efeitos diferentes nas vendas comparando-se o período pré-pandemia e pandemia	Cofirmada
H3: o desempenho da atividade econômica brasileira impactou a venda de chocolates da empresa analisada	Cofirmada
H4: a pandemia afetou negativamente a tendência de vendas de chocolates	Não confirmada
H5: a pandemia alterou o padrão sazonal de vendas de chocolates	Não confirmada
H6: as vendas de chocolates foram influenciadas de acordo com a variação dos índices associados à COVID-19, diminuindo com o agravamento e aumentando com a melhoria destes índices.	Confirmada

Com base nas determinações acerca da confirmação ou refutação das hipóteses mencionadas, é possível organizar os resultados alcançados em consonância com os objetivos desta dissertação se desdobram em contribuições, tanto de natureza teórica quanto prática. Estas contribuições, derivadas diretamente dos resultados de nossa pesquisa, podem ser melhor compreendidas e analisadas através do Quadro 4 a seguir. Este quadro proporciona um panorama mais detalhado e organizado, permitindo uma visão mais clara de como as hipóteses e os objetivos traçados se materializaram em contribuições substanciais para o campo de estudo em questão.

Quadro 4 - Relação entre objetivos, hipóteses, contribuições teóricas e práticas

Objetivos	Hipóteses	Contribuições teóricas	Boas práticas gerenciais
<p>Objetivo Geral: Avaliar o efeito que as estratégias de marketing adotadas ao longo da pandemia da Covid-19 tiveram em vendas de chocolate de uma empresa que atua no mercado brasileiro</p>	<p>H1: as estratégias de marketing utilizadas pela empresa influenciaram as vendas de chocolate no período</p> <p>H2: estratégias de marketing tiveram efeitos diferentes nas vendas comparando-se o período pré-pandemia e pandemia</p> <p>H3: o desempenho da atividade econômica brasileira impactou a venda de chocolates da empresa analisada</p>	<p>Há uma complexa e multifatorial relação entre diferentes estratégias de marketing com as vendas de chocolate, para o período de normalidade "Investimento em Produto" liderou a contribuição para as vendas, no período de mudança "Incentivo por Metas" se destacou. Na fase de crise (2021) o "Investimento em Produto" voltou a liderar, evidenciando a importância do marketing estratégico adaptado ao cenário. Ademais, as descobertas reforçam a literatura existente ao indicar que indicadores econômicos, como inflação e taxa de desocupação, podem influenciar significativamente as vendas em setores específicos.</p>	<p>O gerenciamento estratégico deve ser ágil e diversificado, capaz de adaptar diferentes estratégias de marketing para maximizar as vendas em variadas condições de mercado. Além de se considerar o contexto econômico ao planejar suas estratégias de vendas e marketing.</p>
<p>Objetivo Específico I: Identificar quais foram as estratégias de marketing utilizadas pela empresa estudada no mercado de Chocolates ao longo da crise de COVID-19.</p>	<p>----</p>	<p>----</p>	<p>Os resultados indicam a importância de ser flexível, adaptável e reorientar investimentos durante crises, destacando a importância do marketing digital e manter uma oferta constante de produtos.</p>

Continua na próxima página

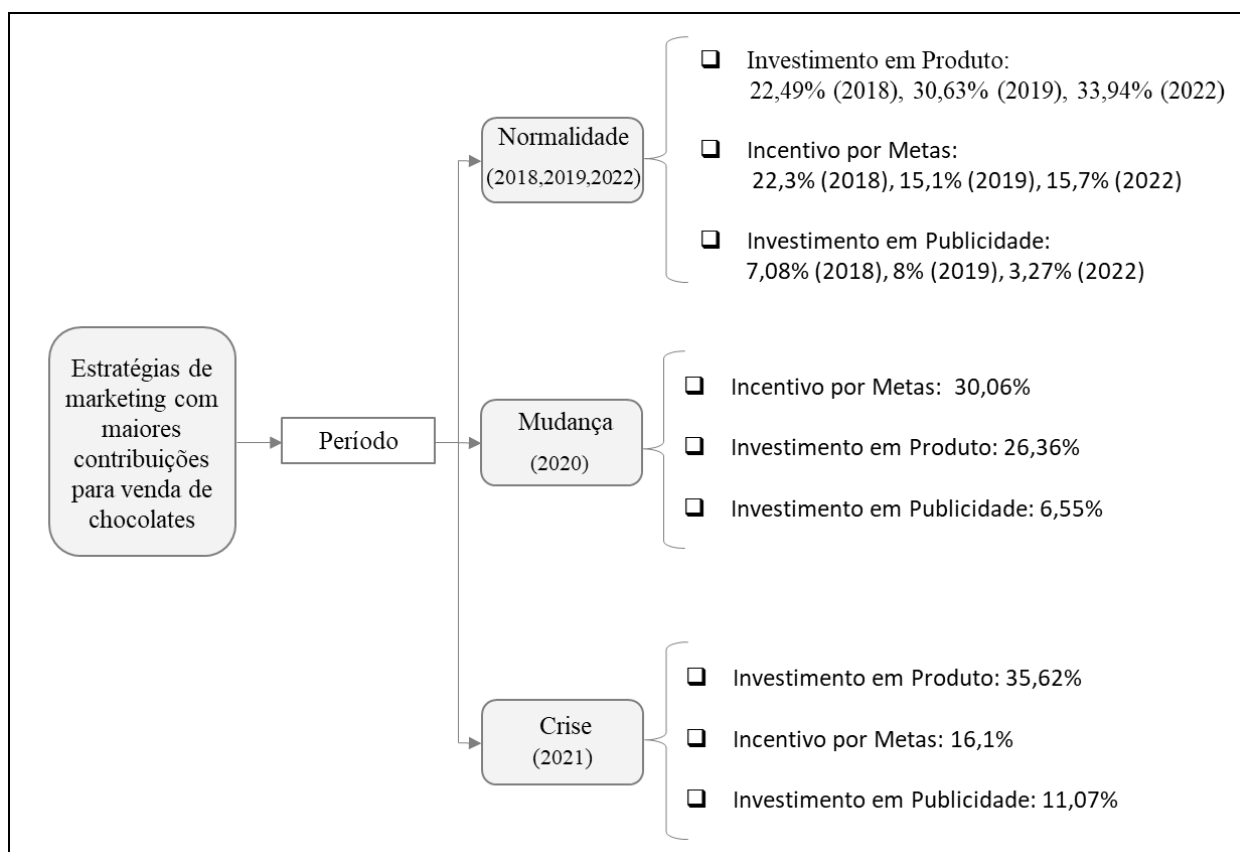
Conclusão do Quadro 4

Quadro 4 - Relação entre objetivos, hipóteses, contribuições teóricas e práticas

Objetivos	Hipóteses	Contribuições teóricas	Boas práticas gerenciais
<p><u>Específico II:</u> Verificar quais mudanças que ocorreram nas vendas de chocolates ao longo da pandemia da COVID-19</p>	<p>H3: o desempenho da atividade econômica brasileira impactou a venda de chocolates da empresa analisada</p>	<p>O estudo expande a compreensão sobre a influência de eventos globais disruptivos nas vendas de produtos específicos, oferecendo um panorama sobre as vendas de chocolates durante a pandemia.</p>	<p>Os insights obtidos indicam que os esforços de marketing e vendas devem considerar a resiliência da demanda por chocolates em tempos de crise e manter o foco no quarto trimestre do ano.</p>
<p><u>Objetivo específico III:</u> Verificar quais as mudanças que ocorreram nas vendas de chocolates ao longo do período pandemia da COVID-19</p>	<p>H4: a pandemia afetou negativamente a tendência de vendas de chocolates</p> <p>H5: a pandemia alterou o padrão sazonal de vendas de chocolates</p>	<p>A pesquisa explora a interação entre a percepção de risco da pandemia COVID-19 e o comportamento do consumidor no contexto específico da indústria de chocolates, destacando a importância do uso de ferramentas digitais para prever e monitorar o comportamento do consumidor.</p>	<p>Os resultados evidenciam a necessidade de gestores serem ágeis e flexíveis para adaptar suas estratégias de vendas e marketing em resposta a flutuações dos indicadores da pandemia, além de considerarem estratégias para minimizar a percepção de risco do consumidor.</p>

Com este entendimento, avançamos para uma síntese organizada dos resultados em um framework de resumo, onde os insights mais significativos ganham destaque. Este resumo é especialmente relevante para elucidar o impacto estratégico das ações de marketing que mais contribuíram para o incremento das vendas de chocolates em cada período. Nesse contexto, as três principais estratégias, detalhadas no Quadro 5 a seguir, lançam luz sobre as descobertas obtidas com o estudo.

Quadro 5 – Framework de resumo dos resultados



5.2. Limitações do estudo e sugestão de estudos futuros

Dentre as limitações deste estudo, destaca-se que apesar de terem sido obtidos os valores de investimento em diversas estratégias de marketing, as mecânicas de execução específicas associadas a cada uma dessas estratégias não foram investigadas. Tal nível de detalhamento pode possibilitar uma compreensão mais aprofundada sobre como as estratégias de marketing adotadas influenciam efetivamente as vendas. Dessa forma, a falta de tal especificidade evidencia um limite quanto à capacidade do estudo de responder completamente à questão da influência direta de cada estratégia de marketing nas vendas de chocolates.

Por motivos de preservação da competitividade da empresa, não foram divulgados dados de Market Share, público alvo do do produto de chocolate estudado. Portanto as conclusões elaboradas ao longo da dissertação apresentam um caráter não generalizável para outras empresas do setor, nem permitem tecer inferências sobre como a empresa se situa no mercado diante das ações de alavancagem de vendas.

No que tange às sugestões para estudos futuros, sugere-se que pesquisas subsequentes explorem o uso de técnicas avançadas de inteligência artificial, como as redes neurais, para a análise dos dados. Adicionalmente, a elaboração de competições entre diferentes algoritmos pode ser uma abordagem útil para eleger a melhor técnica de análise em detrimento do uso de um único algoritmo para realizar as previsões com as variáveis exógenas das séries temporais, como foi realizado nesta dissertação. Além disso, uma perspectiva mais ampla do efeito das estratégias de marketing poderia ser obtida ao se expandir o estudo para diferentes mercados. Isso permitiria uma análise mais generalista dos efeitos nas vendas em diversos mercados, isolando melhor os efeitos das variáveis e oferecendo uma perspectiva mais abrangente das dinâmicas de mercado. Outra sugestão de estudos futuros, envolve poder relacionar os investimentos aportados ao longo da série temporal associado ao market share obtido. Dessa forma o investimento de marketing poderia ganhar uma visão mais holística sobre seu efeito, isolando-o com maior precisão dos demais fatores.

REFERÊNCIAS

- ABICAB. Chocolates: Produção, Exportação e Importação em volume (Mil Ton.). Disponível em: <https://encurtador.com.br/CHIU2>. Acesso em: 20 out. 2023.
- ADAMOWICZ, W. L.; GRAHAM-TOMASI, T. (1991). Revealed preference tests of nonmarket goods valuation methods. *Journal of Environmental Economics and Management*, 20(1), 29–45.
- ADDO, P.C. F.; JIAMING, N.B; KULBO; LIANGQIANG, L. 2020. COVID19: Fear appeal favoring purchase behavior towards personal protective equipment. *The Service Industries Journal* 40 (7–8): 471–490.
- ADDO, P.C. F.; JIAMING, N.B; KULBO; LIANGQIANG, L. 2020. COVID19: Fear appeal favoring purchase behavior towards personal protective equipment. *The Service Industries Journal* 40 (7–8): 471–490.
- ALLEN, M.; NG, S. Economic behavior. In: *Encyclopedia of Applied Psychology*. [S.l.], v. 1, p. 661-666, 2004. doi: 10.1016/B0-12-657410-3/00220-8.
- AKANDE, Y. F. et al. Application of XGBoost Algorithm for Sales Forecasting Using Walmart Dataset. In: SENGODAN, T.; MURUGAPPAN, M.; MISRA, S. (eds). *Advances in Electrical and Computer Technologies. Lecture Notes in Electrical Engineering*, vol 881. Singapore: Springer, 2022. p. 139-148. DOI: 10.1007/978-981-19-1111-8_13.
- AMPOUNTOLOS, A.; SHAW, G.; JAMES, S. The role of social media as a distribution channel for promoting pricing strategies. *Journal of Hospitality and Tourism Insights*, v. 2, n. 1, p. 75-91, 2019.
- AMIRI, S. S.; MOTTAHEDI, S.; LEE, E. R.; HOQUE, S. Peeking inside the black-box: Explainable machine learning applied to household transportation energy consumption. *Computers, Environment and Urban Systems*, v. 88, 2021. doi: 10.1016/j.compenvurbsys.2021.101647

- ANDRADE-MATOS, M.; FUNO, L.; PIMENTEL, T. Chocolates Bean to Bar e a COVID-19: uma análise dos impactos da pandemia na gestão de empresas de chocolates artesanais brasileiras. *Turismo: Visão e Ação*, v. 24, p. 391-412, 2 jun. 2022. 10.14210/rtva.v24n2.p391-412.
- ANTIPOV, E. A.; POKRYSHEVSKAYA, E. B. Interpretable machine learning for demand modeling with high-dimensional data using Gradient Boosting Machines and Shapley values. *Journal of Revenue and Pricing Management*, 2020. doi:10.1057/s41272-020-00236-4.
- ARBELAITZ, O.; GURRUTXAGA, I.; MUGUERZA, J; PÉREZ, J.M.; PERONA, I. An extensive comparative study of cluster validity indices, *Pattern Recogn.* 46 (2013) 243–256.
- ARBOLEDA-FLOREZ, M.; CASTRO-ZULUAGA, C. Interpreting direct sales' demand forecasts using SHAP values. *Production*, v.33, n.e20220035, 2023. Disponível em: <https://doi.org/10.1590/0103-6513.20220035>.
- ARIELY, D. (2008). *Predictably irrational: The hidden forces that shape our decisions* (Revised and expanded ed.). New York, NY: Harper Perennial.
- ARIZA-GARZON, M. J.; ARROYO, J.; CAPARRINI, A.; SEGOVIA-VARGAS, M.-J. Explainability of a Machine Learning Granting Scoring Model in Peer-to-Peer Lending. *IEEE Access*, v. 8, p. 64873–64890, 2020. DOI:10.1109/access.2020.2984412.
- ASGARI, M. M.; DUTT, N; RAHMANI AM. The causality inference of public interest in restaurants and bars on daily COVID-19 cases in the United States: Google Trends analysis. *JMIR Public Health Surveill* 2021 Apr 06;7(4): e22880
- ASTERIADIS, S.; K. KARPOUZIS, N. SHAKER, G.N. YANNAKAKIS. Towards detecting clusters of players using visual and gameplay behavioral cues, *Procedia Comput. Sci.* 15 (2012) 140–147.
- ASTUTI, Retno; SILALAH, Rizky Lutfian Ramadhan; WIJAYA, Galuh Dian Paramita. Marketing Strategy Based on Marketing Mix Influence on Purchasing Decisions of Malang Apples Consumers at Giant Olympic Garden Mall (MOG), Malang City, East Java Province, Indonesia. *Agriculture and Agricultural Science Procedia*, v. 3, 2015, p. 67-71. ISSN 2210-7843. Disponível em: <https://doi.org/10.1016/j.aaspro.2015.01.015>.

- AVEN, T. (2018). How the integration of System 1-System 2 thinking and recent risk perspectives can improve risk assessment and management. *Reliability Engineering & System Safety*, 180, 237–244. doi:10.1016/j.ress.2018.07.031
- ASIEGBU, I. F.; POWEI D. M.; IRUKA, C. (2012), Consumer Attitude: Some Reflections on Its Concept, Trilogy, Relationship with Consumer Behavior, and Marketing Implications *European Journal of Business and Management*. ISSN 2222-1905 (Paper) ISSN 2222-2839. Vol 4, No.13.
- BAKER, S.; BLOOM, N.; DAVIS, S. J.; TERRY, S. "COVID-Induced Economic Uncertainty." NBER Working Paper No. 26983, 2020.
- BANDYOPADHYAY, S. A dynamic model of cross-category competition: theory, tests and applications. *Journal of Retailing*, v. 85, n. 4, p. 468–479, 2009.
- BARDIN, L. *Análise de conteúdo*. São Paulo: Edições 70, 2011.
- BARREDO ARRIETA, A. et al. Explainable Artificial Intelligence (XAI): concepts, taxonomies, opportunities, and challenges toward responsible AI. *Information Fusion*, v.58, p.82-115, 2020. Disponível em: <http://dx.doi.org/10.1016/j.inffus.2019.12.012>.
- BAUMAN, Z. *Modernidade líquida*. Tradução Plínio Dentzien. Rio de Janeiro: Zahar, 2001.
- BERGMEIR, C.; BENÍTEZ, J. M. On the use of cross-validation for time series predictor evaluation. *Information Sciences*, v. 191, p. 192-213, 2012. DOI: 10.1016/j.ins.2011.12.028.
- BETRU, B. T.; ONANA, C. A.; BATCHAKUI, B. Deep learning methods on recommender system: A survey of state-of-the-art. *International Journal of Computer Applications*, v. 162, n. 10, p. 17-22, 2017.
- BODAPATI, A. V. Recommendation systems with purchase data. *Journal of Marketing Research*, v. 45, n. 1, p. 77–93, 2008.
- BUKULUKI, P.; MWENYANGO, H.; KATONGOLE, S.; SIDHVA, D.; PALATTIYIL, G. The Socio-economic and Psychosocial Impact of Covid-19 Pandemic on Urban Refugees in Uganda. *Social Sciences & Humanities Open*, v. 2, p. 100045, 2020. doi: 10.1016/j.ssaho.2020.100045.

- BUREAU OF LABOR STATISTICS. Curtin, S. U.S. Consumer Expenditure Surveys Program Report Series. (2022). Disponível em: <https://www.bls.gov/cex/research_papers/pdf/curtin-2020-annual-COVID-impact.pdf>. Acesso em 25/04/2022.
- CADBY, J. Can COVID-19 Melt the Craft Chocolate Industry?. *Food ethics* 6, 8 (2021). <https://doi.org/10.1007/s41055-021-00087-8>
- CALINSKI, T.; J. HARABASZ, A dendrite method for cluster analysis, *Commun. Statist. Theor. Methods* 3 (1974) 1–27.
- CAMPITELLI, G., & GOBET, F. (2010). Herbert Simon’s decision-making approach: Investigation of cognitive processes in experts. *Review of General Psychology*, 14(4), 354–364.
- CANNITO L.; ANZANI S.; BORTOLOTTI A.; PALUMBO R.; CECCATO I.; DI CROSTA A.; et al. Temporal Discounting of Money and Face Masks During the COVID-19 Pandemic: The Role of Hoarding Level. *Front Psychol.* (2021); 12: 642102. <https://doi.org/10.3389/fpsyg.2021.642102> PMID: 34177697.
- CHEN, C. H.; KHOO, L. P.; YAN, W. PDCS—a product definition and customization system for product concept development. *Expert Systems with Applications*, v. 28, n. 3, p. 591-602, 2005.
- CHEN, D. N. et al. A Web-based personalized recommendation system for mobile phone selection: Design, implementation, and evaluation. *Expert Systems with Applications*, v. 37, n. 12, p. 8201-8210, 2010.
- CHEN, L. H.; KO, W. C.; YEH, F. T. Approach based on fuzzy goal programming and quality function deployment for new product planning. *European Journal of Operational Research*, v. 259, n. 2, p. 654-663, 2017.
- CHEN, T.; GUESTRIN, C. Xgboost: A Scalable Tree Boosting System. In: proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining. San Francisco, CA, USA, August 13–17, 2016. p. 785–794.
- CHENARIDES, L.; GREBITUS, C.; LUSK, J.; PRINTEZIS, I. Food Consumption Behavior During the COVID-19 Pandemic. *Agribusiness*, v. 37, 2020. doi: 10.1002/agr.21679.

- CHOI, J. (2003). Developing an economic indicator system (a forecasting technique) for the hotel industry. *International Journal of Hospitality Management*, 22(2), 53–61.
- CHOU, S.-F., HORNG, J.-S., SAM LIU, C.-H., & LIN, J.-Y. (2020). Identifying the critical factors of customer behavior: An integration perspective of marketing strategy and components of attitudes. *Journal of Retailing and Consumer Services*, 55, 102113.
- CUNNINGHAM, W. A., ZELAZO, P. D., PACKER, D. J., & VAN BAVEL, J. J. (2007). The Iterative Reprocessing Model: A Multilevel Framework for Attitudes and Evaluation. *Social Cognition*, 25(5), 736–760.
- DAGUM, E. B. Time series modeling and decomposition. *Statistica*, v. 70, n. 4, p. 433-457, 2010.
- DAMASIO, A. R. (1994). *Descartes' error: Emotion, rationality and the human brain*. New York: Putnam.
- DARDOT, P.; LAVAL, C. *A nova razão do mundo: ensaio sobre a sociedade neoliberal*. 1. ed. São Paulo: Boitempo, 2016. Tradução: Mariana Echalar.
- DASTON, L. 1987. “Rational Individuals versus Laws of Society: From Probability to Statistics.” *The Probabilistic Revolution 1*: 295–304.
- DAVIES, D.L; D.W. Bouldin, A cluster separation measure, *IEEE Trans. Pattern Anal. Mach. Intell. PAMI-1* (1979) 224–227.
- DE SOUZA, F.S.H. et al. An overview of Brazilian working age adults vulnerability to COVID-19. *Sci Rep*, v. 12, n. 1, p. 2798, 2022. DOI: <https://doi.org/10.1038/s41598-022-06641-6>.
- DEGLI ESPOSTI, P., MORTARA, A., & ROBERTI, G. (2021). Sharing and Sustainable Consumption in the Era of COVID-19. *Sustainability*, 13(4), 1903.
- DI CROSTA, A.; CECCATO I; MARCHETTI, D.; LA MALVA, P.; MAIELLA, R.; et al. (2021) Psychological factors and consumer behavior during the COVID-19 pandemic. *PLOS ONE* 16(8): e0256095.

- DING, K. X., LEV, B., PENG, X., SUN, T., & VASARHELYI, M. A. (2020). Machine learning improves accounting estimates: Evidence from insurance payments. *Review of Accounting Studies*, 25(3), 1098–1134.
- EAGLY, A. H., & CHAIKEN, S. (1993). The nature of attitudes. In A. H. Eagly, & S. Chaiken (Eds.). *The psychology of attitudes* (pp. 1–22). Orlando, FL: Harcourt Brace Jovanovich College.
- EFFENBERGER, M.; KRONBICHLER, A.; SHIN J.; MAYER, G.; TILG, H.; PERCO, P. Association of the COVID-19 pandemic with internet search volumes: A Google Trends analysis. *Int J Infect Dis* 2020 Jun; 95:192-197
- EGIDI, M. (2005). From Bounded Rationality to Behavioral Economics. *SSRN Electronic Journal*.
- EIKA, L., MOGSTAD, M., & VESTAD, O. L. (2020). What can we learn about household consumption expenditure from data on income and assets? *Journal of Public Economics*, 104163.
- ELIAZ, K., & OK, E. A. (2006). Indifference or indecisiveness? Choice-theoretic foundations of incomplete preferences. *Games and Economic Behavior*, 56(1), 61–86.
- ELSTER, J. 1989. Social Norms and Economic Theory. *Journal of Economic Perspectives* 3 (4): 99–117. doi:10.1257/jep.3.4.99.
- FERGUSON, H. *The Lure of Dreams: Sigmund Freud and the Construction of Modernity*. Londres: Routledge, 1996, p. 205.
- FISCHER, E.; CASTILHOS, R. B.; FONSECA, M. J. The Qualitative Interview in Marketing and Consumer Research: Paradigmatic Approaches and Guidelines. *Brazilian Journal of Marketing - BJM Revista Brasileira de Marketing – ReMark Edição Especial – Vol. 13, n. 4. Setembro/ 2014*.
- FINUCANE, M. L. et al. The Affect Heuristic in Judgments of Risks and Benefits. *Journal of Behavioral Decision Making* 13 (2000): 1-17.
- FRIEDMAN, M. 1984[1953]. “The Methodology of Positive Economics.” In *The Philosophy of Economics: An Anthology*, edited by D. Hausman. Cambridge: Cambridge University Press.

- FRIEDMAN, J. H. Greedy Function Approximation: a Gradient Boosting Machine. *Ann. Stat.*, v. 29, n. 5, p. 1189-1232, 2001. DOI: 10.1214/aos/1013203451.
- FU, X.; CHEN, Y.-T. SHI, I. BOSE, S. Cai, User segmentation for retention management in online social games, *Decis. Support. Syst.* 101 (2017) 51–68.
- GARG, A.; TAI, K. (2013). Comparison of statistical and machine learning methods in modelling of data with multicollinearity. *International Journal of Modelling, Identification and Control*, 18(4), 295. doi:10.1504/ijmic.2013.053535.
- GONZALEZ-BENITO, O.; MARTIEZ-RUIZ, M. P.; MOLLA-DESCALS, A. Retail pricing decisions and product category competitive structure. *Decision Support Systems*, v. 49, n. 1, p. 110–119, 2010.
- GRANOT, E.; GREENE, H. A Structural Guide to Interviewing as Qualitative Marketing Research: The Three Interview Series Model. In: *Developments in Marketing Science: Proceedings of the Academy of Marketing Science*, 2014. p. 77–81. DOI: 10.1007/978-3-319-11779-9_33.
- GOOGLE Support. FAQ about Google Trends data. Disponível em: <<https://support.google.com/trends/answer/4365533?hl=en>>. Acesso em: 24/04/2022.
- GUJARATI, D. N.; PORTER, D. C.; GUNASEKAR, S. (2012). *Basic econometrics*. Tata mcgraw-hill education.
- HABIB, M. (2011). *Supply Chain Management (SCM): Theory and Evolution*. Supply Chain Management - Applications and Simulations. doi:10.5772/24573
- HACIOĞLU-HOKE, S.; KÄNZIG, D.; SURICO, P. The Distributional Impact of the Pandemic. *European Economic Review*, v. 134, p. 103680, 2021. doi: 10.1016/j.euroecorev.2021.103680.
- HALUK KÖKSAL, M.; ÖZGÜL, E. (2007). The relationship between marketing strategies and performance in an economic crisis. *Marketing Intelligence & Planning*, 25(4), 326–342. doi:10.1108/02634500710754574
- HAGBERG, J.; SUNDSTROM, M.; EGELS-ZANDÉN, N. The digitalization of retailing: an exploratory framework. *International Journal of Retail & Distribution Management*, v. 44, n. 7, p. 694-712, 2016.

- HAGEN, L., UETAKE, K., YANG, N., BOLLINGER, B., CHANEY, A. J. B., DZYABURA, D., ZHU, Y. (2020). How can machine learning aid behavioral marketing research? *Marketing Letters*. doi:10.1007/s11002-020-09535-7.
- HAN J, PEI J, KAMBER M. *Data mining: concepts and techniques*. Amsterdam: Elsevier; 2011.
- HAWKINS, Del I.; MOTHERSBAUGH, David L.; BEST, Roger J. *Comportamento do Consumidor – Construindo a Estratégia de Marketing*. Rio de Janeiro: Elsevier, 2010.
- HE, W.; XU, L. A state-of-the-art survey of cloud manufacturing. *International Journal of Computer Integrated Manufacturing*, v. 28, n. 3, p. 239-250, 2015.
- HENDRAWATI, T.; WIGENA, H. A.; SUMERTAJAYA, M.; SARTONO, B. Performance Evaluation of AIC and BIC in Time Series Clustering with Piccolo Method. In: *Proceedings of the 1st International Conference on Statistics and Analytics, ICSA 2019, 2-3 August 2019, Bogor, Indonesia*. DOI: 10.4108/eai.2-8-2019.2290340.
- HILL, R. C.; GRIFFITHS, W. E.; LIM, G. C. (2018). *Principles of econometrics*. John Wiley & Sons.
- HINES, P.; FRANCIS, M.; FOUND, P. Towards lean product lifecycle management. *Journal of Manufacturing Technology Management*, v. 17, p. 866-887, 2006.
- HOBBS, J. E. (2021). Food supply chain resilience and the COVID-19 pandemic: What have we learned? *Canadian Journal of Agricultural Economics/Revue Canadienne D'agroeconomie*, 69(2), 189–196.
- HU, Y.; PENG, Q.; HU, X.; YANG, R. Web service recommendation based on time series forecasting and collaborative filtering. In: *IEEE INTERNATIONAL CONFERENCE ON WEB SERVICES, 2015. Proceedings [...]*. IEEE, 2015. p. 233-240.
- HUSNA, A.; AMIN, S. H.; SHAH, B. (2021). Demand Forecasting in Supply Chain Management Using Different Deep Learning Methods. In: _____. *Demand Forecasting and Order Planning in Supply Chains and Humanitarian Logistics*. [S.l.]: [s.n.]. DOI: 10.4018/978-1-7998-3805-0.ch005.

- JAIN, V. K., & KUMAR, S. (2020). Predictive analysis of emotions for improving customer services. In *Natural Language Processing: Concepts, Methodologies, Tools, and Applications* (pp. 808–817). IGI Global.
- JACOB, K.; HUDSON, S.; BUSH, M. *Tools for Survival: An Analysis of Financial Literacy Programs For Lower-Income Families*. Woodstock Institute, 2000.
- JIAN, M., & JUNG, C. (2021). Semi-supervised kernel matrix learning using adaptive constraint-based seed propagation. *Pattern Recognition*, 112, 107750.
- JIANG, Y.; SHANG, J.; LIU, Y.; MAY, J. Redesigning promotion strategy for e-commerce competitiveness through pricing and recommendation. *International Journal of Production Economics*, v. 167, p. 257–270, 2015.
- JIN, Y.; SU, M. Recommendation and repurchase intention thresholds: a joint heterogeneity response estimation. *International Journal of Research in Marketing*, v. 26, n. 3, p. 245–255, 2009.
- JO, H.; SHIN, E.; KIM, H. (2020). Changes in Consumer Behaviour in the Post-COVID-19 Era in Seoul, South Korea. *Sustainability*, 13(1), 136.
- JOCEVSKI, M.; ARVIDSSON, N.; MIRAGLIOTTA, G.; GHEZZI, A.; MANGIARACINA, R. Transitions towards omni-channel retailing strategies: a business model perspective. *International Journal of Retail & Distribution Management*, v. 47, n. 2, p. 78–93, 2019.
- JUSTER, F. T. (1990). Rethinking utility theory. *Journal of Behavioral Economics*, 19(2), 155–179.
- KAHNEMAN, Daniel; TVERSKY, Amos. Prospect theory: an analysis of decision under risk. *Econometrica*, 47, p.263-291, 1979.
- KANTAR MEDIA. 2018 Print & digital promotion trends: The view from above. 2018. Disponível em: <https://www.kantarmedia.com/us/thinking-and-resources/blog/2018-print-digital-promotion-trends-the-view-from-above>. Acesso em: 11/06/2023
- KARDES, F. R.; KALYANARAM, G. Order-of-entry effects on consumer memory and judgment: an information integration perspective. *Journal of Marketing research*, 29, p.343-357, 1992.

KARCH, J. Improving on Adjusted R-Squared. *Collabra: Psychology*, v. 6, n. 1, 2020. DOI: 10.1525/collabra.343.

KAUR, M.; KANG, S. Market Basket Analysis: Identify the changing trends of market data using association rule mining. *Procedia Computer Science*, v. 85, p. 78-85, 2016.

KEMP, S. Digital 2020: Sudan — DataReportal – Global Digital Insights, 2020. Disponível em: <https://publicadministration.un.org/egovkb/en-us/Data/Country-Information/id/162-Sudan/dataYear/2020>. Acesso em: 30/06/2023.

KIM, R.Y. 2020. The Impact of COVID-19 on consumers: Preparing for digital sales. *IEEE Engineering Management Review*.

KIM, S.S.; KIM, J.; BADU-BAIDEN, F.; GIROUX, M.; CHOI, Y. 2021. Preference for robot service or human service in hotels? Impacts of the COVID-19 pandemic. *International Journal of Hospitality Management*, 93.

KNOWLES, S.; ALLEN, D.; DONNELLY, A.; FLYNN, J.; GALLACHER, K.; LEWIS, A.; McCORKLE, G.; MISTRY, M.; WALKINGTON, P.; DRINKWATER, J. More than a method: trusting relationships, productive tensions, and two-way learning as mechanisms of authentic co-production. *Research Involvement and Engagement*, v. 7, 2021. doi: 10.1186/s40900-021-00262-5.

KRAMOLIŠ, J.; KOPEČKOVÁ, M. Product Placement: A Smart Marketing Tool Shifting a Company to the Next Competitive Level. *Journal of Competitiveness*, v. 5, n. 4, p. 98-114, dez. 2013.

KÖKSAL, M. H.; ÖZGÜL, E. The relationship between marketing strategies and performance in an economic crisis. *Marketing Intelligence & Planning*, v.25, n.4, p.326-342, 2007. doi:10.1108/02634500710754574.

KONUS, U., VERHOEF, P.C., NESLIN, S.A., 2008. Multichannel shopper segments and their covariates. *J. Retail* 84 (4), 398–413.

KOTLER, P.; ARMSTRONG, G. *Principles of marketing*. New York, NY: Pearson Education, 2010.

- KOTLER, P.; KELLER, K. L. *Administração de marketing*. São Paulo: Pearson Prentice Hall, 12^a ed., 2006.
- KUBOTA, S. The macroeconomics of COVID-19 exit strategy: the case of Japan. *The Japanese Economic Review*, v. 72, 2021. doi: 10.1007/s42973-021-00091-x.
- KUHN, M., & JOHNSON, K. (2013). *Applied Predictive Modeling*. Springer, New York, NY.
- KUMAR, V., RAMACHANDRAN, D., & Kumar, B. (2021). Influence of new-age technologies on marketing: A research agenda. *Journal of Business Research*, 125, 864–877.
- KUSHWAHA, T., SHANKAR, V., 2013. Are multichannel customers really more valuable? The moderating role of product category characteristics. *J. Mark.* 77 (4), 67–85.
- KWOK, Linchi; TANG, Yingying; YU, Bei. The 7 Ps marketing mix of home-sharing services: Mining travelers' online reviews on Airbnb. *International Journal of Hospitality Management*, v. 90, 2020, p. 102616. ISSN 0278-4319. Disponível em: <https://doi.org/10.1016/j.ijhm.2020.102616>.
- LAHTINEN, V.; DIETRICH, T.; RUNDLE-THIELE, S. Long live the marketing mix. Testing the effectiveness of the commercial marketing mix in a social marketing context. *Journal of Social Marketing*, v. 10, n. 3, p. 357-375, 2020.
- LARA, B.; GANDINI, M.; GANTES, P.; MATTEUCCI, S. Trends and Land Surface Phenological Responses to Climate Variability in the Argentina Pampas. *CIG*, v. 46, n. 2, p. 581-602, Sep. 2020. DOI: <https://doi.org/10.18172/cig.4310>.
- LEE, K.; HA, I. “Steve.” (2012). Exploring the Impacts of Key Economic Indicators and Economic Recessions in the Restaurant Industry. *Journal of Hospitality Marketing & Management*, 21(3), 330–343. doi:10.1080/19368623.2011.611752
- LEEFLANG, P. S. H.; PARREÑO SELVA, J.; VAN DIJK, A.; WITTINK, D. R. Decomposing the sales promotion bump accounting for cross-category effects. *International Journal of Research in Marketing*, v. 25, n. 3, p. 201–214, 2008.
- LEVINSON, S. C. (1995) Interactional biases in human thinking. In: *Social intelligence and interaction*, ed. E. Goody. Cambridge University Press. [aKES].

LEWIS, C.D. (1982). Industrial and business forecasting methods. London: Butterworths

LIANG, Y. et al. Product marketing prediction based on XGboost and LightGBM algorithm. In: proceedings of the 2nd international conference on artificial intelligence and pattern recognition - AIPR '19. 2019. p. 1-7. DOI: 10.1145/3357254.3357290.

LIU, D. R.; SHIH, Y. Y. Integrating AHP and data mining for product recommendation based on customer lifetime value. Information Management, v. 42, n. 3, p. 387-400, 2005.

LIU, N., ZHANG, F., WEI, C., JIA, Y., SHANG, Z., SUN, L., et al., 2020. Prevalence and predictors of PTSS during COVID-19 outbreak in China hardest-hit areas: gender differences matter. Psychiatr. Res. 287, 112921.

LOEWENSTEIN, G. F.; WEBER, E. U.; HSEE, C. K.; WELCH, N. (2001). Risk as feelings. Psychological Bulletin, 127, 267–286.

LONDHE, B. R. Marketing Mix for Next Generation Marketing. In: Symbiosis Institute of Management Studies Annual Research Conference (SIMSARC13). Procedia Economics and Finance, v. 11, p. 335-340, 2014. doi: 10.1016/S2212-5671(14)00201-9.

LUNDBERG, S. GitHub - slundberg/shap: a game theoretic approach to explain the output of any machine learning model. 2019. Disponível em: <https://github.com/slundberg/shap>. Acesso em: 24 jan. 2022.

LUNDBERG, S.; LEE, S.-I. A unified approach to interpreting model predictions. arXiv, v. 1705.07874v2, p. 1-10, 2017. Disponível em: <https://doi.org/10.48550/arXiv.1705.07874>. Acesso em: dia mês. ano.

LUNDBERG, S. M.; ERION, G. G.; LEE, S.-I. Consistent individualized feature attribution for tree ensembles. arXiv, v. 1802.03888v3, p. 1-9, 2019. Disponível em: <https://doi.org/10.48550/arXiv.1802.03888>. Acesso em: dia mês. ano.

MALTA, C. D. et al. Consumo de bebidas alcoólicas e direção de veículos nas capitais brasileiras e no Distrito Federal, segundo dois inquéritos nacionais de saúde. Revista Brasileira de Epidemiologia, v. 18, p. 214-223, 2015. doi: 10.1590/1980-5497201500060019.

McCARTHY, E. J. Basic Marketing. IL: Richard D. Irwin, 1964.

- MCDANIEL, C.D.; GATES, R.H. 2015. Marketing research. 10th ed. Hoboken, NJ: Wiley
- MALHOTRA, N. K. Pesquisa de marketing: foco na decisão I Naresh K. Malhotra; tradução Opportunity Translations; revisão técnica Maria Cecília Laudisio e Guilherme de Farias Shiraishi-- 3. ed. --Sao Paulo: Pearson Prentice Hall, 2011.
- MARCILIO, W. E.; ELER, D. M. From explanations to feature selection: assessing SHAP values as feature selection mechanism. In: 33rd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI), 2020, Rio de Janeiro. Anais. Rio de Janeiro: IEEE, 2020. p. 1-8. DOI: 10.1109/sibgrapi51738.2020.00053.
- MARTÍNEZ, A., SCHMUCK, C., PEREVERZYEV, S., PIRKER, C., & HALTMEIER, M. (2020). A machine learning framework for customer purchase prediction in the nolo contractual setting. *European Journal of Operational Research*, 281(3), 588–596.
- MASON, A. N.; NARCUM, J.; MASON, K. (2021) ‘Social media marketing gains importance after Covid-19’, *Cogent Business and Management*. *Cogent*, 8(1). doi: 10.1080/23311975.2020.1870797.
- MCCARTHY, David; MIKKOLA, Kalle; THOMAS, Teruji. Utilitarianism with and without expected utility. *Journal of Mathematical Economics*, v. 87, p. 77-113, 2020. ISSN 0304-4068. Disponível em: <https://doi.org/10.1016/j.jmateco.2020.01.001>.
- MENG, Y. et al. What makes an online review more helpful: an interpretation framework using XGBoost and shap values. *Journal of Theoretical and Applied Electronic Commerce Research*, v.16, n.3, p.466-490, 2020. Disponível em: <http://dx.doi.org/10.3390/jtaer16030029>.
- MIRJALILI, V.; RASCHKA, S.; ROSS, A. FlowSAN: Privacy-Enhancing Semi-Adversarial Networks to Confound Arbitrary Face-Based Gender Classifiers. *IEEE Access*, v. PP, p. 1-1, 2019. doi: 10.1109/ACCESS.2019.2924619.
- MONCADA-TORRES, A.; VAN MAAREN, M.C.; HENDRIKS, M.P. et al. Explainable machine learning can outperform Cox regression predictions and provide insights in breast cancer survival. *Sci Rep* 11, 6968 (2021). <https://doi.org/10.1038/s41598-021-86327-7>.
- MORDOR INTELLIGENCE. Tamanho do Mercado de Chocolate na Europa e Análise de Participação – Tendências e Previsões de Crescimento (2023 – 2028). Disponível em:

<https://www.mordorintelligence.com/pt/industry-reports/europe-chocolate-market>.
Acesso em: 20 out. 2023.

NAKANO, S., & KONDO, F. N. (2018). Customer segmentation with purchase channels and media touchpoints using single source panel data. *Journal of Retailing and Consumer Services*, 41, 142–152.

NETZER, L., GUTENTAG, T., KIM, M. Y., SOLAK, N., & Tamir, M. (2018). Evaluations of emotions: Distinguishing between affective, behavioral and cognitive components. *Personality and Individual Differences*, 135, 13–24.

NIELSEN. Key Consumer Behavior Thresholds Identified as the Coronavirus Outbreak Evolves–Nielsen. 2020. Disponível em: https://www.nielsen.com/us/en/insights/article/2020/key-consumerbehavior-thresholds-identified-as-the-coronavirus-outbreak-evolves/?utm_source=sfmc&utm_medium=email&utm_campaign=newswire&utm_content=3-18-2020

NISBET, R.; MINER, G.; YALE, K. 2018. *Handbook of Statistical Analysis and Data Mining Applications (Second Edition)*, Academic Press. P. 279-288.

NGAI, E. W.T.; WU, Y. Machine learning in marketing: A literature review, conceptual framework, and research agenda. *Journal of Business Research* 145 (2022) 35–48.

NORUSIS, M. J. *SPSS 13.0 guide to data analysis*. Upper Saddle River: Prentice Hall, 2005.

NUTI, SV.; WAYDA, B.; RANASINGHE, I.; WANG, S.; DREYER, RP.; CHEN SI, et al. The use of Google Trends in health care research: A systematic review. *PLoS One* 2014;9(10):e109583.

OZILI, P. K. (2022). The Acceptable R-Square in Empirical Modelling for Social Science Research. *Em Social Research Methodology and Publishing Results*. SSRN Electronic Journal. DOI: 10.2139/ssrn.4128165.

PAUL, S. R.; ZHANG, X. Testing for normality in linear regression models. *Journal of Statistical Computation and Simulation*, v. 80, n. 10, p. 1101-1113, 2010. DOI: 10.1080/00949650902964275.

PEKER, S., KOCYIGIT, A., & EREN, P. E. (2017). A hybrid approach for predicting customers' individual purchase behavior. *Kybernetes*, 46(10), 1614–1631.

- PINDYCK, R. S.; RUBINFELD, D. L. 2009. Microeconomia. Ed. Pearson Universidades, 7ª edição.
- QUELCH, J.; JOCZ, K. E. How to Market in a Downturn 2009. Harvard Business Review 87(4): <https://hbr.org/2009/04/how-to-market-in-a-downturn-2>
- RAHMANI, K.; EMAMISALEH, K.; YADEGARI, R. Quality function deployment and new product development with a focus on marketing mix 4P model. Asian Journal of Research in Marketing, v. 4, n. 2, p. 98-108, 2015.
- RAJAGOPAL. (2019). Consumer Behavior: External Factors. Contemporary Marketing Strategy, 35–63.
- REINDERS, C.; ACKERMANN, H., Yang; M. Y.; Rosenhahn, B. (2019). Learning Convolutional Neural Networks for Object Detection with Very Little Training Data. Multimodal Scene Understanding, 65–100.
- RENNER, B.; GAMP, M.; SCHMÄLZLE, R.; SCHUPP, H. T. (2015). Health Risk Perception. International Encyclopedia of the Social & Behavioral Sciences, 702–709.
- RILEY, G. (2006). Income elasticity of demand. Disponível em: <http://tutor2u.net/economics/revision-notes/as-markets-income-elasticity-of-demand.html>
- ROBERTS, K. What strategic investment should you make during a recession to gain competition. Strategy & Leadership, v.31, n.4, p.31-39, 2003.
- ROJAS, Mariano; MÉNDEZ, Alfonso; WATKINS-FASSLER, Karen. The hierarchy of needs: empirical examination of Maslow's theory and lessons for development. World Development, v. 165, 2023. ISSN 0305-750X. Disponível em: <https://doi.org/10.1016/j.worlddev.2023.106185>.
- ROKACH L. A survey of clustering algorithms. In: Data mining and knowledge discovery handbook, pages 269–298. Springer, 2010.
- ROTH, K. P. & DIAMANTOPOULOS, A. (2009). Advancing the country image construct. Journal of Business Research, 62 (1), 726-740.

- ROUSSEEUW, P.J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis, *J. Comput. Appl. Math.* 20 (1987) 53–65.
- ROVETTA, A. The Impact of COVID-19 on Conspiracy Hypotheses and Risk Perception in Italy: Infodemiological Survey Study Using Google Trends *JMIR Infodemiology* (2021);1(1): e29929.
- SAMSON, A.; ARIELY, D.; BARDEN, P.; FEHR, G.; GOHMANN, T.; JÄGER, M.; KAMM, A.; MILES, R.; O'FARRELL, S.; STOTT, H. *The behavioral economics guide* 2015. 2015.
- SANDERS, N. Book Review of Demand Management Best Practices by Colleen Crum with George Palmatier (2003). *Foresight: The International Journal of Applied Forecasting*, v. 1, p. 49-50, 2005.
- SANTOS, L. J.; OLIVEIRA, A. V. M.; ALDRIGHI, D. M. (2021). Testing the differentiated impact of the COVID-19 pandemic on air travel demand considering social inclusion. *Journal of Air Transport Management*, 94, 102082.
- SEELING, M.; SCAVARDA, L.; THOMÉ, A. M. A sales and operations planning application in the Brazilian subsidiary of a multinational chemical company. *Brazilian Journal of Operations & Production Management*, v. 16, p. 424-435, 2019. doi: 10.14488/BJOPM.2019.v16.n3.a6.
- SEN, A. 1977. “Rational Fools: A Critique of the Behavioral Foundations of Economic Theory.” *Philosophy and Public Affairs* 6: 317–344.
- SELTEN R. (1999) What is Bounded Rationality? SBF Discussion Paper B-454
- SENT, E.-M. 2008. “Rationality, History of the Concept.” In *The New Palgrave Dictionary of Economics*, edited by S. N. Durlauf and L. E. Blume. London: Palgrave Macmillan.
- _____. (2018). Rationality and bounded rationality: you can't have one without the other. *The European Journal of the History of Economic Thought*, 1–17.
- SEVERO, E. et al. Impact of the COVID-19 pandemic on environmental awareness, sustainable consumption and social responsibility: Evidence from generations in Brazil and Portugal. *Journal of Cleaner Production*, v. In Press, p. 124947, 2020. doi: 10.1016/j.jclepro.2020.124947.

- SERAFINI, G.; PARMIGIANI, B.; AMERIO, A.; AGUGLIA, A.; SHER, L.; AMORE, M. The psychological impact of COVID-19 on the mental health in the general population. *QJM : monthly journal of the Association of Physicians*, v. 113, 2020. doi: 10.1093/qjmed/hcaa201.
- SHAMA, A. Management and consumers in an era of stagflation. *Journal of Marketing*, v.42, n.3, p.43-52, 1978.
- SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, v. 52, n. 3/4, p. 591-611, 1965.
- SHAPLEY, L. S. A value for n-person games. In: KUHN, H. W.; TUCKER, A. W. (Eds.). *Contributions to the theory of games (annals of mathematics studies)*. Princeton: Princeton University Press, v. 2, n. 28, p. 307–317, 1953.diferença.
- SHIM, J. J.; MOON, M.; SONG, W.S.; Lee. 2021. Antecedents of purchase intention at Starbucks in the context of covid-19 pandemic. *Sustainability* 13 (4): 1758.
- SHIVELY, T. S.; ANSLEY, C. F.; KOHN, R. Fast Evaluation of the Distribution of the Durbin-Watson and Other Invariant Test Statistics in Time Series Regression. *Journal of the American Statistical Association*, v. 85, n. 411, p. 676–685, 1990. DOI: 10.1080/01621459.1990.10474922.
- SHETH, J. Impact of Covid-19 on Consumer Behavior: Will the Old Habits Return or Die? *Journal of Business Research*, v. 117, 2020. doi: 10.1016/j.jbusres.2020.05.059.
- SHERIDAN, A.; ANDERSEN, A.; HANSEN, E.; JOHANNESSEN, N. Social distancing laws cause only small losses of economic activity during the COVID-19 pandemic in Scandinavia. *Proceedings of the National Academy of Sciences*, v. 117, p. 202010068, 2020. doi: 10.1073/pnas.2010068117.
- SICILIANO, Tony (1993), Purchase Intent: Facts from Fiction. *Marketing Research*, 21, 25.
- SILVERSTEIN, M. J.; SAYRE, K. (2009). The Female Economy. *Harvard Business Review*, 87(9), 46–53.
- SIMON, H. A. (1957). *Models of man, social and rational: Mathematical essays on rational human behavior*. New York: Wiley.

- _____. 1984[1963]. "Testability and Approximation." In *The Philosophy of Economics*, edited by D. Hausman. Cambridge: Cambridge University Press.
- _____. (1957). *Models of man, social and rational: Mathematical essays on rational human behavior*. New York: Wiley.
- SIT, J. K.; HOANG, A.; INVERSINI, A. Showrooming and retail opportunities: a qualitative investigation via a consumer-experience lens. *Journal of Retailing and Consumer Services*, v. 40, p. 163-174, 2018.
- SLOVIC, P. *The Perception of Risk* (Sterling, VA: EarthScan, 2000).
- SOLOMON, M. *Comportamento do consumidor*. 9a. ed. Porto Alegre: Bookman, 2011.
- SOUSA-PINTO B.; ANTO A.; CZARLEWSKI W.; ANTO JM.; FONSECA, JA.; BOUSQUET, J. Assessment of the impact of media coverage on COVID-19-related Google Trends data: Infodemiology study. *J Med Internet Res* (2020) Aug 10;22(8): e19611.
- STANOVICH, K. E., & West, R. F. 1999) Discrepancies between normative and descriptive models of decision making and the understanding/acceptance principle. *Cognitive Psychology* 38:349–85. [DH, JJ, arKES].
- STARK, J. *Product lifecycle management*. In: *Product lifecycle management*. Cham: Springer, 2015. v. 1, p. 1-29.
- STROIE, B. L. M. (2014). Predicting Consumer Behavior with Artificial Neural Networks. *Procedia Economics and Finance*, 15, 238–246.
- SUDIGDO, A.; KHALIFA, G. S. A.; ABUELHASSAN, A. E. Driving Islamic Attributes, Destination Security Guarantee & Destination Image to Predict Tourists' Decision to Visit Jakarta. *International Journal on Recent Trends in Business and Tourism*, v.3, n.1, p.59–65, 2019.
- SYNTETOS, A. A.; BABAI, Z.; BOYLAN, J. E.; KOLASSA, S.; NIKOLOPOULOS, K. Supply chain forecasting: Theory, practice, their gap and the future. *European Journal of Operational Research*, v. 252, n. 1, p. 1–26, 2016. DOI: 10.1016/j.ejor.2015.11.010.

- SZAJNOGA, D.; KLIMEK-TULWIN, M.; PIEKUT, A. COVID-19 lockdown leads to changes in alcohol consumption patterns. Results from the Polish national survey. *Journal of Addictive Diseases*, 2020. doi: 10.1080/10550887.2020.1848247.
- TAKEMURA, K. 2021. Escaping from bad decisions, In *Perspectives in Behavioral Economics and the Economics of Beh.* Academic Press.
- TAO, F.; CHENG, J.; QI, Q.; ZHANG, M.; ZHANG, H.; SUI, F. Digital twin-driven product design, manufacturing and service with big data. *International Journal of Advanced Manufacturing Technology*, v. 94, n. 9, p. 3563-3576, 2017.
- TERZI, S. et al. Product lifecycle management-from its history to its new role. *International Journal of Product Lifecycle Management*, v. 4, n. 4, p. 360-389, 2010.
- TYBOUT, Alice. M.; CALKINS, Tim. 2006. Branding: fundamentos, estratégias e alavancagem de marcas: implementação, modelagem e checklists: experiências de líderes de mercado. p. 73-90. In: CARPENTER, G. S.; NAKAMOTO, K. *Estratégias de marcas competitivas*. Editora Atlas, São Paulo, SP, Brasil.
- TVERSKY, A. (1977) "On the Elicitation of Preferences: Descriptive and Prescriptive Considerations." In D. Bell, R. Kenney, and H. Raiffa eds., *Conflicting Objectives in Decisions*. New York: Wiley.
- TVERSKY A. and KAHNEMAN D., (1974) "Judgement under uncertainty: heuristics and biases, *Science*, 185, pp.1124-1131
- _____. (1987) "Rational Choice and the Framing of Decisions" in Hogart R. M., Reder M. W. *Rational choice - The Contrast between Economics and Psychology*, Chicago, The University of Chicago Press; previously published in *The Journal of Business*, (1986) Vol.59, No.4, Part2: The behavioral Foundations of economic theory, pp.251-278.
- UPTON, E.; NUTTALL, W. J. Fuel panics: Insights from spatial agent-based simulation. *IEEE Transactions on Intelligent Transportation Systems*, v. 15, n. 4, p. 1499-1509, 2014.
- VAN DAMME, Eric. *Encyclopedia of Social Measurement*, 2005
- VAN HARREVELD, F., NOHLEN, H. U., & SCHNEIDER, I. K. (2015). The ABC of Ambivalence. *Advances in Experimental Social Psychology*, 285–324.

- VAN STEENBERGEN, R., & Mes, M. (2020). Forecasting demand profiles of new products. *Decision Support Systems*, 113401.
- VOGEL, W.; LASCH, R. Complexity drivers in manufacturing companies: a literature review. *Logistics Research*, v. 9, n. 1, p. 25, 2016. Disponível em: <http://dx.doi.org/10.1007/s12159-016-0152-9>.
- XGBOOST DEVELOPERS. XGBoost Parameters. 2023. Disponível em: <https://xgboost.readthedocs.io/en/latest/parameter.html>. Acesso em: 18 jun. 2023.
- WALTERS, R. Assessing the impact of retail price promotions on product substitution, complementary purchase, and interstore sales displacement. *Journal of Marketing*, v. 55, n. 2, p. 17–28, 1991.
- WANG, J. W.; CHENG, C. H.; HUANG, K. C. Fuzzy hierarchical TOPSIS for supplier selection. *Applied Soft Computing*, v. 9, n. 1, p. 377-386, 2009.
- WANG, L.; LIU, Z.; LIU, A.; TAO, F. Artificial intelligence in product lifecycle management. *The International Journal of Advanced Manufacturing Technology*, v. 114, n. 3-4, p. 771-796, 2021.
- WANG, Y. et al. Combining Probabilistic Load Forecasts. *IEEE Transactions on Smart Grid*, v. 10, n. 1, p. 1-1, 2018. DOI: 10.1109/tsg.2018.2833869.
- WEBER, M. 1999[1904]. “The Area of Economics, Economic Theory, and the Ideal Type.” In *Essays in Economic Sociology*, edited by M. Weber and R. Swedberg. Princeton: Princeton University Press.
- WEI, Y. Z., MOREAU, L., & JENNINGS, N. R. (2005). Learning users’ interests by quality classification in market-based recommender systems. *IEEE Transactions on Knowledge and Data Engineering*, 17(12), 1678–1688.
- WESTERVELD, J. J. L. et al. Forecasting transitions in the state of food security with machine learning using transferable features. *Science of The Total Environment*, v. 786, p. 147366, 2021. DOI: 10.1016/j.scitotenv.2021.147366.
- WIERING, M., & VAN OTTERLO, M. (Eds.). (2012). *Reinforcement Learning. Adaptation, Learning, and Optimization*.

- WILEY, J.; SONS, I. R. Multiple R, r^2 , R^2 , R Square, R^2 Adjusted. In: Statistics from A to Z: Confusing Concepts Clarified, 2016. p. 274–319. DOI: 10.1002/9781119272021.ch12.
- WOLFF, K.; LARSEN, S.; ØGAARD, T. (2019). How to define and measure risk perceptions. *Annals of Tourism Research*, 79, 102759.
- WORLD HEALTH ORGANIZATION, 2020. Mental Health and Psychosocial Considerations during the COVID-19 Outbreak, 18 March 2020 (No. WHO/2019-nCoV/MentalHealth/ 2020.1). World Health Organization.
- YAO, Q. et al. Taking human out of learning applications: a survey on automated machine learning. *arXiv*, v. 1810.13306v4, p. 1-20, 2018. Disponível em: <https://doi.org/10.48550/arXiv.1810.13306>.
- YENIDOGAN, I. et al. Bitcoin Forecasting Using ARIMA and PROPHET. In: 2018 3rd international conference on computer science and engineering (UBMK). 2018. p. 467-472. DOI: 10.1109/ubmk.2018.8566476.
- ZEHIR, C.; SAVI, F.Z. (2004), “A field research about implications of organizational downsizing on employees working for Turkish public banks”, *Journal of American Academy of Business*, Vol. 5 Nos 1/2, pp. 343-9.
- ZHANG, Z. et al. Profit maximization analysis based on data mining and the exponential retention model assumption with respect to customer churn problems. In: IEEE INTERNATIONAL CONFERENCE ON DATA MINING WORKSHOP (ICDMW), 2015. Proceedings. IEEE, 2015. p. 1093-1097.
- ZHANG, Z.; MA, M.; POPKOWSKI LESZCZYC, P. T. L.; ZHUANG, H. The Influence of Coupon Duration on Consumers’ Redemption Behavior and Brand Profitability. *European Journal of Operational Research*, 2019.
- ZHOU, J.; LI, P.; ZHOU, Y.; WANG, B.; ZANG, J.; MENG, L. Toward New-Generation Intelligent Manufacturing. *Engineering*, v. 4, n. 1, p. 11-20, 2018.