

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

GUILHERME GOMES CARDIM MATTOS

FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE DE RIBEIRÃO PRETO

MARINA LOURENÇÃO

UNIVERSIDADE DE SÃO PAULO (USP)

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

1. INTRODUÇÃO

O comportamento do consumidor é uma área de pesquisa diversa, sendo explorado através da economia, economia comportamental, psicologia, administração e marketing. Na economia comportamental e psicologia, se examinam as influências cognitivas, sociais e emocionais no comportamento econômico, assumindo limites para a racionalidade e padrões de viés (SAMSON, 2015; ARIELY, 2008; KAHNEMAN, 2011). Ademais, observa-se que o consumidor contemporâneo é complexo e expressa individualidade através do consumo (FERGUSON, 1996; HAWKINS, 2010; DARDOT, 2016). Bauman (2001) descreve que o curso da história envolve mudança na tomada de decisões de consumo, de atendimento de necessidades para a realização de desejos. Neste contexto, para manter a demanda alinhada com a oferta crescente, as empresas precisam produzir consumidores atraídos pelo desejo de adquirir novos bens (FERGUSON, 1996; BAUMAN, 2001; DARDOT, 2016).

Dentre as formas de adaptação estratégica para atingimento dos objetivos corporativos, está o mix de marketing (LONDHE, 2014). Este conceito proposto por McCarthy (1964) e popularizado como "4Ps", refere-se à combinação de produto, preço, promoção e praça, usada para produzir a resposta desejada do mercado-alvo (KOTLER & ARMSTRONG, 2010). Oesman (2010) argumenta que o mix de marketing é uma combinação de variáveis ou atividades controladas pela empresa para influenciar a reação dos clientes. Assim, as empresas podem agir de modo a conquistar seus principais objetivos: lucros, volume de vendas, participação no mercado, retorno sobre o investimento (ISORAITE, 2016). A utilização dessas ferramentas está associada à gestão de demanda, que contempla outro conjunto de mecanismos que são cruciais para monitorar a eficácia das estratégias de marketing e apoiar a tomada de decisões na cadeia de suprimentos (CRUM & PALMATIER, 2003; SEELING et al., 2019).

Empresas realizam gestão da demanda usando 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 *Machine Learning* (ML) são utilizados para previsões, descoberta de estruturas ocultas e relações significativas entre os dados (MIRJALILI, 2015),

inserindo a gestão da demanda como etapa essencial para tomada de decisão em marketing (SEELING et al., 2019). Para além da complexidade inerente ao contexto de marketing, a pandemia de COVID-19 suscitou um novo nível de especificidades (ZHOU, 2021), 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). Assim como, há evidências sobre 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 (SZAJNOGA et al., 2020). Este estudo examina o impacto das estratégias de marketing na venda de chocolates durante a pandemia de COVID-19, utilizando dados de uma empresa multinacional no mercado brasileiro, assim como técnicas estatísticas, Inteligência Artificial (IA) e interpretabilidade de IA. O objetivo é fornecer contribuições valiosas para a compreensão do efeito das estratégias de marketing em tempos de normalidade, mudança e crise.

1.1. Contexto investigado

Ao considerar que a pandemia acarretou mudanças consideráveis em âmbito econômico e comportamental da sociedade, 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?

2. REFERENCIAL TEÓRICO

2.1. Economia comportamental

Segundo Campitelli & Gobet (2010), a tomada de decisão não é feita por agentes perfeitamente racionais, mas sim por indivíduos com racionalidade limitada. Tversky (1977) e Kahneman e Tversky (1974; 1979) apontam que o processo decisório é influenciado por processos cognitivos que moldam as preferências e crenças, conduzindo por vezes a erros sistemáticos. A heurística do afeto, conceito proposto por Kahneman (2011), demonstra que as preferências individuais influenciam a percepção de argumentos, levando ao viés de disponibilidade, em que eventos recentes influenciam fortemente as decisões. Isso é exemplificado pela tendência de pessoas adotarem medidas preventivas logo após desastres, embora a atenção caia no tempo (KAHNEMAN, 2011).

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

A gestão do composto de marketing (4Ps - Produto, Preço, Praça, Promoção) é crucial na criação de vantagem competitiva para empresas de todas as escalas (KRAMOLIŠ & KOPEČKOVÁ, 2013; LAHTINEN et al, 2020). Detalhamento abaixo.

2.2.1. Gestão de produto

Desde os anos 80, o Gerenciamento do Ciclo de Vida do Produto (do inglês *Product Lifecycle Management* -PLM) tem sido implementado em processos de engenharia de manufatura (WANG et. al 2021). O PLM abrange desde a análise de mercado e design do produto, ao desenvolvimento de processos, manufatura, distribuição, uso e serviço pós-venda (TERZI et. al 2010, STARK 2015). Notavelmente, a interseção entre PLM e inteligência artificial está impulsionando inovações em design de produto, manufatura e operação (WANG et al., 2021; CHEN et. al 2006; ZHANG et. al 2015)

2.2.2. Gestão de preço

De acordo com Jiang et. al (2015), a obtenção do melhor efeito na decisão de compra pode ser alcançada através da otimização da promoção de preços e recomendação de produtos, pois a perda com o desconto pode ser compensada pelos ganhos com os itens regulares. Promoções de preço são uma estratégia vital, trazendo benefícios como reconhecimento de marca e incremento de vendas (WALTERS, 1991). A otimização conjunta da promoção de preços e recomendação, amparada por TI, tem se mostrado eficaz para alavancagem de vendas (JIANG et. al 2015; JIN & SU, 2009).

2.2.3. Gestão de promoção

Promoções são ferramentas de incentivo para estimular compras maiores e mais rápidas entre os clientes-alvo (KOTLER & ARMSTRONG, 2010), que embora seja uma estratégia importante, Lahtinen et. al. (2020) evidenciou que a gestão integrada do composto de marketing (4P) é mais eficaz que apenas ações exclusivas de promoção. 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 U\$ 497 bi, segundo Kantar Media (2018).

2.2.4. Gestão de praça

Segundo a concepção original de McCarthy (1960), "Praça" refere-se a “onde”, “quando” e “por quem” o produto será vendido, envolvendo canais de distribuição, variedade de produtos, localização das lojas, gerenciamento de estoque e transporte (NESLIN et al., 2006). Com a ascensão do comércio eletrônico, surgiram novos canais

de distribuição, desafiando o controle tradicional da capacidade (HAGBERG et al., 2015). O modelo de varejo *omnichannel*, que integra canais físicos, online e móveis, está mudando a forma como os varejistas interagem com seus clientes (SOYSAL et al 2022). A implementação de uma estratégia *omnichannel* é complexa, pois exige integração de sistemas e uma cultura organizacional de suporte (HERTER et. al 2021).

2.3. 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 que essencialmente abrange a orquestração das etapas produtivas desde a obtenção e aquisição de matérias-primas à entrega dos produtos aos usuários (HUGOS, 2011). Trata-se de uma coordenação estratégica para melhorar o desempenho a longo prazo das cadeias de suprimentos (COOPER et. al 1997). A gestão de *supply chain* eficiente tem o potencial de melhorar o valor do cliente e gerar uma vantagem competitiva sustentável (PORTER, 1985). Habib (2011) destaca que a previsão é fundamental à tomada de decisões na SCM, e a inovação tecnológica tem permitido às empresas coletar, processar e analisar grandes volumes de dados para melhorar a precisão, otimizar o tempo de processamento e reduzir a interação humana (ARBOLEDA-FLOREZ & CASTRO-ZULUAGA, 2023; YAO et al., 2018).

2.4. Pandemia no Brasil e no mundo

Ao final de 2019 houve uma grande alteração ambiental que afetou as pessoas no mundo, suscitada pela pandemia de COVID-19 decretada em 11/03/2020 (WORLD HEALTH ORGANIZATION, 2020). A pandemia 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 (LIU et al., 2020; ZHOU, 2021). Segundo Renner et al (2015) e Wolff et al (2019), a percepção de risco envolve uma avaliação cognitiva que pode ser influenciada pelo afeto, conduzindo as pessoas a avaliar riscos de acordo com a gravidade e a probabilidade de possíveis resultados (LOEWENSTEIN et al., 2001).

2.5. Inteligência artificial e Machine Learning

O *Machine Learning* (ML) é uma das categorias da inteligência artificial (IA) (JIAN et. al, 2021) e é dividido em quatro subcategorias: *Supervised learning*, *Unsupervised learning*, *Semi-supervised learning* e *Reinforcement learning*. O *Supervised learning* utiliza algoritmos para prever uma variável dependente com base em variáveis independentes (MA & SUN, 2020; NGAI et. al 2022). O *Unsupervised learning* utiliza variáveis independentes para realizar agrupamentos por similaridade (NGAI et. al

2022; MA & SUN, 2020). O *Semi-supervised learning* integra dados não rotulados e amostras rotuladas para capturar a estrutura global dos dados e realizar inferências sobre a variável dependente (REINDERS et. al 2019; JIAN et. al, 2021). O *Reinforcement learning*, que se baseia em experiências passadas e aprendizado contínuo por tentativa e erro, não depende de dados rotulados (WIERING & OTTERLO, 2012; WEI et al., 2005).

Ademais, as tecnologias de IA e ML estão sendo aplicadas em várias áreas, devido à sua capacidade de identificar padrões e facilitar a tomada de decisão (KUMAR et al., 2021). Essas ferramentas são cada vez mais usadas para prever comportamento do consumidor e permitem a alocação eficiente de recursos (MARTÍNEZ et al., 2020). No entanto, uma grande parte desses modelos de IA são classificados como "caixas-pretas" devido à sua complexidade, dificultando o entendimento e confiança em suas previsões (AMIRI et al., 2021). 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 (LUNDBERG & LEE, 2017). Nesse contexto que emergiu a técnica de valor de SHAP, que avalia a contribuição marginal de cada variável para uma previsão de IA e ML (SHAPLEY, 1953; ARIZA-GARZON et. al 2020).

3. MÉTODO

Este estudo possui métodos mistos, com uma etapa qualitativa e outra quantitativa.

3.1. 1ª Etapa: Estudo Qualitativo

Seguindo o método exploratório qualitativo de Malhotra (2011), a primeira fase buscou uma compreensão profunda do fenômeno em estudo: as estratégias de marketing adotadas durante a pandemia de COVID-19. Quatro gestores da empresa foram entrevistados sobre os impactos da pandemia nas operações da empresa e as mudanças estratégicas realizadas. Foi realizada a análise de conteúdo e categorização proposta por Bardin (2011) para conduzir a análise dos dados, que propõe um conjunto de técnicas sistemáticas e objetivas para descrever o conteúdo das mensagens de maneira que permita uma análise estruturada mais organizada e profunda dos conteúdos obtido. As perguntas realizadas constam no Quadro 1.

Quadro 1 – Perguntas 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?

Os dados foram coletados online via *Google Meet*, para vide descrição 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

3.2. 2ª Etapa: Estudo Quantitativo

A segunda fase, de natureza quantitativa longitudinal e descritiva, utilizou dados secundários internos de uma multinacional do setor alimentício. De acordo com Malhotra (2011), a pesquisa descritiva propõe 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. Foram coletados dados sobre o volume de vendas de chocolates e investimentos em marketing da empresa, bem como indicadores econômicos externos como IPCA, taxa de desocupação e nível de atividade do comércio varejista. Todos os dados foram tratados em conformidade com a Lei Geral de Proteção de Dados. Para análise dos dados quantitativos, este estudo utilizou de *Spark* e para modelagem estatística, *Python*. Com o objetivo de avaliar o efeito das estratégias de marketing durante a pandemia nas vendas de chocolate foi realizado uma regressão múltipla através de ML com o modelo *XGBoost*. Tendo como variável dependente as vendas de chocolate e como variáveis independentes, indicadores econômicos brasileiros e os investimentos de marketing. Posteriormente

aplicou-se técnicas de SHAP para interpretabilidade dos resultados obtidos e avaliação do efeito das estratégias de marketing nas vendas de chocolate.

4. RESULTADOS

Os entrevistados afirmaram que a empresa adotou estratégias em duas grandes perspectivas ao longo do período. A primeira foi a revisão dos gastos e investimentos, estratégia alinhada à perspectiva de Roberts (2003), em que momentos de crise empresas devem planejar seus orçamentos de marketing a longo prazo e rever os gastos a curto prazo. A segunda, envolve a adoção de estratégias digitais, haja visto que as vendas digitais se tornaram essenciais, confirmando a perspectiva de Soysal et. al (2022). A empresa também investiu em visibilidade, antecipação da demanda e oferta constante de produtos, seguindo a prática de inovação em produto baseada em big data. As entrevistas permitiram categorizar os investimentos realizados para alavancar as vendas em:


- Incentivo por metas: descontos ao atingimento uma meta pré-estabelecida.
- Publicidade: investimentos realizados na criação e manutenção de materiais publicitários, e anúncios em mídias digitais, televisão e rádio.
- Produto: alavancagem da visibilidade do produto no PDV com a aquisição de gôndolas extras, paletes de exibição ou área da prateleira exclusiva
- Relacionamento com cliente: investimento não atrelado à performance dos clientes, como restauração de lojas, propagandas compartilhadas e ações promocionais em datas comemorativas dos PDVs

4.1. Construção do modelo

O modelo de ML *XGBoost*, utilizado neste estudo, é personalizado com vários parâmetros: *regressor* como tipo de modelo, base score de 0,5, '*gbtree*' como *booster*, 100 estimadores e parâmetros de regularização específicos para evitar *overfitting*. O modelo '*gbtree*' emprega a combinação de árvores de decisão. Os parâmetros de regularização - *reg_lambda*, *reg_alpha*, *gamma* são ajustados para manter a robustez do modelo e controlar a divisão da árvore e a subamostragem de observações e variáveis (XGBOOST DEVELOPERS,2023). O conjunto de dados utilizado para modelagem foi dividido em: treino e teste. O conjunto de treino é usado para aprendizado do modelo durante o processo de desenvolvimento, enquanto o conjunto de teste é usado para avaliar os resultados, técnica tradicional de avaliação de resultados de ML chamada *cross-validation* (WANG et. al, 2018). 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 treinamento com 85% dos dados. Com o treino concernindo ao período de 2018/05/01 a 2022/03/01, e o Teste de 2022/04/01 a 2022/12/01.

Retirou-se as variáveis altamente correlacionadas, restando apenas 15 utilizadas, estratégia sugerida por McDaniel & Gates (1996) para lidar com a multicolinearidade. Modelos construídos sem esse tipo de tratamento podem levar a uma análise errônea, (GARG & TAI, 2013). Para Hair et al. (1995), os valores de correlação indicativos de multicolinearidade seriam de magnitude superiores a 0,80, isso não se observou com os dados utilizados. O teste de correlação de Pearson evidenciou um valor máximo positivo entre “Montante depositado em poupança (R\$)” e “Preço Kg/R\$” em 0,71. Enquanto o maior valor negativo se deu entre “Mês” e “taxa desocupação” em -0,54, vide figura 1.



4.2. Resultados do modelo

O modelo de ML utilizado nesta pesquisa demonstrou que 66% das vendas de chocolates são explicadas pelas 15 variáveis independentes utilizadas, com um R² de 0,659, que está dentro do intervalo aceitável de Ozili (2022). Os testes BIC em 236,42 e AIC de 235,149 sugerem que o modelo apresenta estabilidade significativa para os

resíduos, o teste Durbin-Watson de 1,114 indica que não há autocorrelação nos resíduos de acordo com a tabela 1.

Tabela 1 - Resumo modelo de Machine Learning

<i>Modelo</i>	R²	R² ajustado	BIC	AIC	Durbin-Watson
2	0,659	0,457	236,420	235,149	1,114

O Erro Percentual Absoluto Médio (MAPE) foi de 6,7%, o que, segundo Lewis (1982), indica previsões altamente precisas. O Erro Absoluto Médio (MAE) e a Raiz do Erro Quadrático Médio (RMSE) foram 237,34 e 326,71, respectivamente de acordo com a tabela 2.

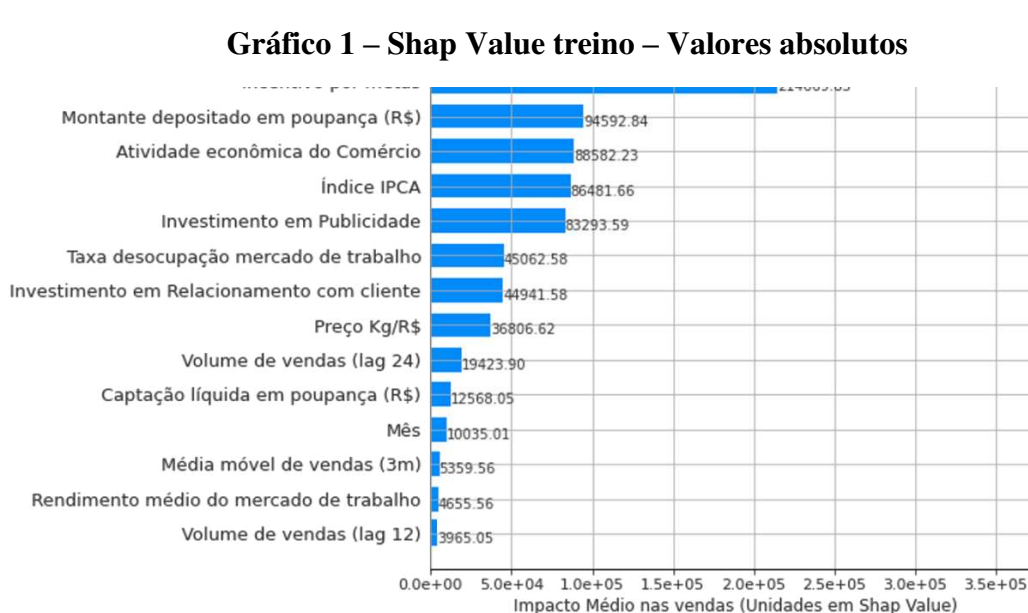
Tabela 2 - Assertividade modelo de Machine Learning

<i>Modelo</i>	MAE	RMSE	MAPE
2	237,34	326,71	6,7%

4.3. Interpretabilidade

A análise dos valores absolutos do SHAP identificou "Investimento em Produto" e "Incentivo por Metas" como as principais determinantes do modelo. Outras variáveis, como "montante de depósito em poupança", "atividade econômica do comércio", "índice IPCA" e "investimento em publicidade", embora menos influentes, também contribuíram significativamente para o modelo, de acordo com a gráfico 1.

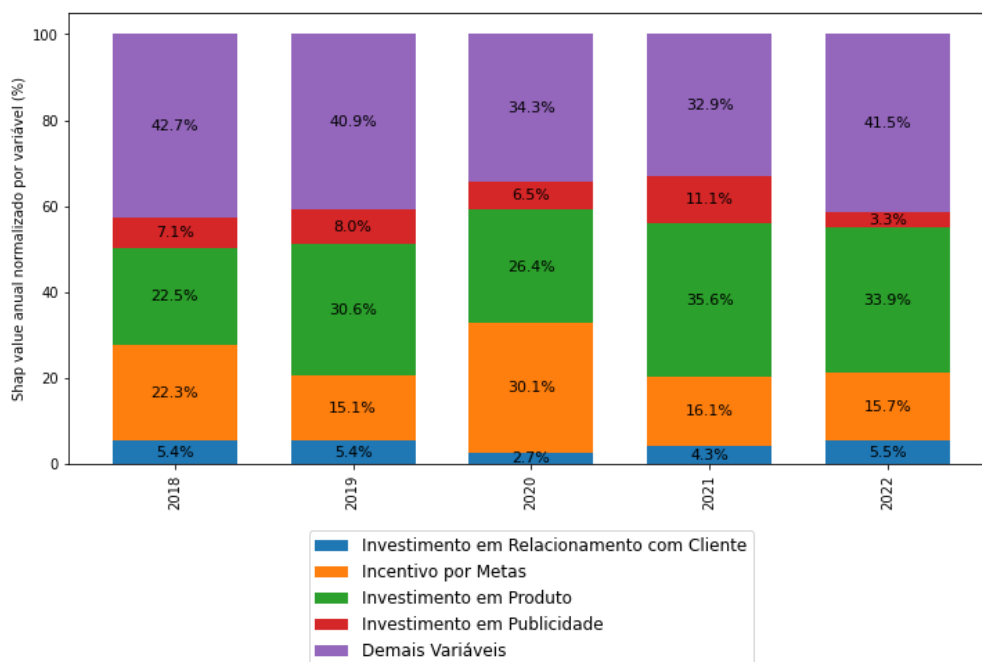
Gráfico 1 – Shap Value treino – Valores absolutos



Através das unidades SHAP, os efeitos das variáveis independentes foram normalizados entre 0 e 100% para uma análise comparativa mais precisa do impacto

relativo, facilitando a identificação das variáveis mais relevantes. No Gráfico 2, impacto das estratégias de marketing adotadas durante a pandemia de Covid-19 nas vendas de chocolate oi avaliado de modo a apresentar as contribuições variáveis ano após ano, com ênfase nas estratégias de marketing.

Gráfico 2 – Efeito das estratégias entre anos



As estratégias de marketing contribuíram com 50% para as vendas de chocolates em todos os anos avaliados, superando o impacto combinado das demais variáveis que atingiram no máximo 42,7%. Entre as estratégias, o incentivo por metas e o investimento em produto destacaram-se, enquanto o relacionamento com o cliente e a publicidade mostraram menos impacto. Os detalhes dessas contribuições estão dispostos na Tabela 3.

Tabela 3 - Efeito normalizado das estratégias na venda de chocolates

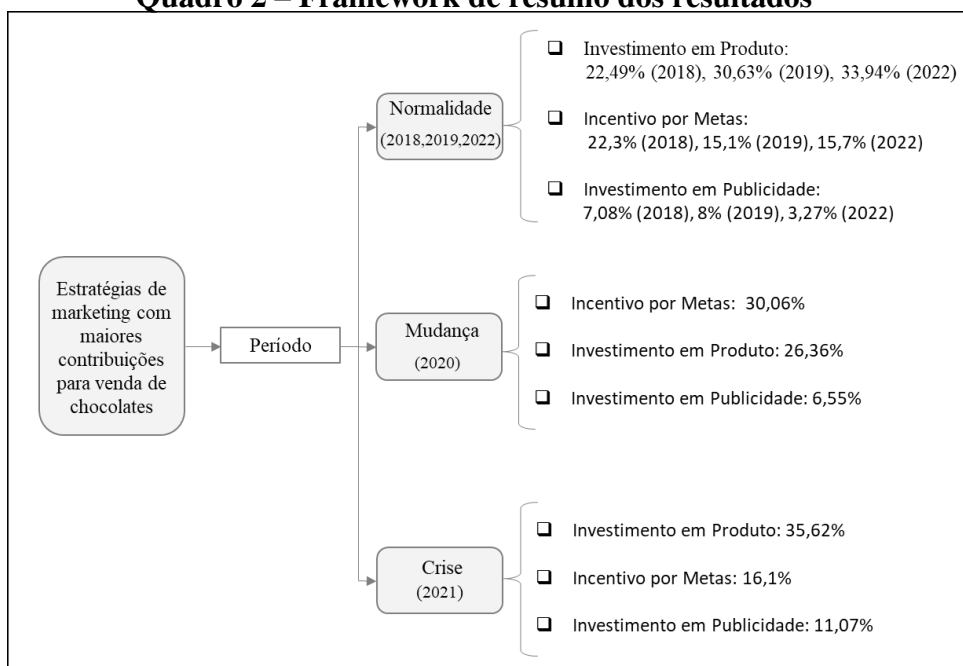
<i>Variável</i>	2018	2019	2020	2021	2022
	(%)				
Investimento em Relacionamento com cliente	5,42	5,39	2,73	4,30	5,52
Incentivo por metas	22,33	15,07	30,06	16,10	15,74
Investimento em Produto	22,49	30,63	26,36	35,62	33,94
Investimento em Publicidade	7,08	8,00	6,55	11,07	3,27
Demais variáveis	42,67	40,92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

No período de mudança, ou seja, a transição da normalidade pré-pandemia para a vigência inicial da crise 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.

Com este entendimento, avançamos para uma síntese organizada dos resultados em um framework de resumo, onde os insights mais significativos ganham destaque. Este resumo elucida 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 2 a seguir, lançam luz sobre as descobertas obtidas

Quadro 2 – Framework de resumo dos resultados



5. CONCLUSÃO

O objetivo da pesquisa foi amplamente atingido com base nos resultados apresentados. 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. Esses achados revelam que a relação entre o investimento em marketing e o impacto nas vendas é complexa e multifatorial. 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.

5.1. Contribuição Tecnológica-Social

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. 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. No contexto prático 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.

REFERÊNCIAS

- 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
- 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.
- BAKER, S.; BLOOM, N.; DAVIS, S. J.; TERRY, S. "COVID-Induced Economic Uncertainty." NBER Working Paper No. 26983, 2020.
- 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.

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.

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.

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.

DARDOT, P.; LAVAL, C. A nova razão do mundo: ensaio sobre a sociedade neoliberal. 1. ed. São Paulo: Boitempo, 2016. Tradução: Mariana Echalar.

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.

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.

HAWKINS, Del I.; MOTHERSBAUGH, David L.; BEST, Roger J. *Comportamento do Consumidor – Construindo a Estratégia de Marketing*. Rio de Janeiro: Elsevier, 2010.

IŞORAITË, M. Marketing Mix Theoretical Aspects. *INTERNATIONAL JOURNAL OF RESEARCH – GRANTHAALAYAH*, v. 4, p. 25-37, 2016. doi: 10.5281/zenodo.56533.

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.

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

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.

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

_____.; KELLER, K. L. *Administração de marketing*. São Paulo: Pearson Prentice Hall, 12^a ed., 2006.

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.

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.

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

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 output of any machine learning model. 2019. Disponível em: <https://github.com/slundberg/shap>. Acesso em: 24 jan. 2022.

_____.; 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>.

_____.; 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.

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 Cecilia 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.

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>.

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.

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.

RENNER, B.; GAMP, M.; SCHMÄLZLE, R.; SCHUPP, H. T. (2015). Health Risk Perception. *International Encyclopedia of the Social & Behavioral Sciences*, 702–709.

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.

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.

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.

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.

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.

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.

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.

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.

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.

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.

WIERING, M., & VAN OTTERLO, M. (Eds.). (2012). *Reinforcement Learning. Adaptation, Learning, and Optimization*.

WOLFF, K.; LARSEN, S.; ØGAARD, T. (2019). How to define and measure risk perceptions. *Annals of Tourism Research*, 79, 102759.

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.

ZHANG, Z. et al. Profit maximization analysis based on data mining and the 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.