

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
ESCOLA DE ADMINISTRAÇÃO  
DEPARTAMENTO DE CIÊNCIAS ADMINISTRATIVAS**

**LUCAS AUGUSTO SARTORI**

**A ADESÃO À RECOMENDAÇÃO DE PRODUTOS REALIZADA POR  
INTELIGÊNCIA ARTIFICIAL NO EMAIL MARKETING DA DEMOCRATA  
CALÇADOS**

**Porto Alegre**

**2024**

LUCAS AUGUSTO SARTORI

**A ADESÃO À RECOMENDAÇÃO DE PRODUTOS REALIZADA POR  
INTELIGÊNCIA ARTIFICIAL NO EMAIL MARKETING DA DEMOCRATA  
CALÇADOS**

Trabalho de conclusão de curso de graduação apresentado ao Departamento de Ciências Administrativas da Universidade Federal do Rio Grande do Sul, como requisito parcial para a obtenção do grau de Bacharel em Administração.

Orientador: Prof. Dr. Vinicius Andrade Brei

Porto Alegre  
2024

## RESUMO

Considerando a tendência do uso de Inteligência Artificial para personalização no Marketing Digital, o presente trabalho tem por objetivo analisar a adesão à recomendação de produtos realizada por inteligência artificial no e-mail marketing da Democrata Calçados. Com a revisão de literatura disponível, foi possível compreender sobre o funcionamento das principais ferramentas do mercado e sobre como a Inteligência Artificial vem sendo aplicada de forma eficaz no contexto do Marketing Digital, especificamente no envio de e-mails personalizados. Para o experimento, foi retirado um recorte da base de clientes da Democrata Calçados a partir de três segmentações: compradores engajados, usuários engajados e novos usuários. Cada um desses segmentos foi submetido a um teste A/B para analisar o impacto e a adesão à recomendação de produtos realizada por inteligência artificial em comparação com a recomendação de produtos mais vendidos do site. Os resultados obtidos forneceram *insights* sobre o comportamento do consumidor da empresa nos canais de e-mail marketing e sobre as funcionalidades e limitações da recomendação de produtos por inteligência artificial. A análise dos dados coletados nos testes A/B indica que não houve diferença significativa nas taxas de clique, cliques em recomendações, sessões engajadas ou descadastros.

**Palavras-chave:** E-mail Marketing; personalização; inteligência artificial; CRM; privacidade; comportamento do consumidor; teste A/B; conversão.

## ABSTRACT

Considering the trend towards the use of Artificial Intelligence for personalization in Digital Marketing, the aim of this study is to analyse adherence to product recommendations made by artificial intelligence in the email marketing of Democrata Calçados. By reviewing the available literature, it was possible to understand how the main tools on the market work and how Artificial Intelligence has been applied effectively in the context of Digital Marketing, specifically in sending personalized emails. For the experiment, a cross-section of Democrata Calçados' customer base was taken from three segmentations: engaged buyers, engaged users and new users. Each of these segments was subjected to an A/B test to analyze the impact and adherence to the product recommendation made by artificial intelligence compared to the recommendation of more best-selling products on the site. The results obtained provided insights into the company's consumer behavior on email marketing channels and into the functionalities and limitations of product recommendation by artificial intelligence. Analysis of the data collected in the A/B tests indicates that there was no significant difference in click-through rates, clicks on recommendations, engaged sessions or unsubscribes.

**Keywords:** E-mail Marketing; personalization; artificial intelligence; CRM; privacy; consumer behavior; A/B testing; conversion.

## LISTA DE FIGURAS

Figura 1- Ordem de cenários da recomendação de Inteligência Artificial .....	24
Figura 2 - Ordem de cenários da recomendação padrão .....	25
Figura 3 - Fluxo do usuário para o recebimento do e-mail .....	26
Figura 4 - Template utilizado nos disparos.....	27

## LISTA DE TABELAS

Tabela 1 - Cenários que exigem um parâmetro de item ou categoria para a recomendação de produtos.....	15
Tabela 2 - Cenários baseados no perfil de Inteligência Preditiva do usuário e no comportamento pessoal do site.....	16
Tabela 3 - Esses cenários são baseados no comportamento agregado coletado do site.....	17
Tabela 4 – Comportamento da base .....	30
Tabela 5 - Relatório de entregas .....	30
Tabela 6 - Relatório de aberturas.....	30
Tabela 7 - Resultado do teste A/B - Aberturas .....	31
Tabela 8 - Relatório de Cliques .....	32
Tabela 9 - Resultado do teste A/B - CTOR .....	33
Tabela 10 - Resultados do teste A/B - Cliques em Recomendações .....	33
Tabela 11 - Relatório de descadastrros.....	34
Tabela 12 - Resultado do teste A/B - descadastrros .....	34
Tabela 13 - Relatório de pós-cliques .....	35
Tabela 14 - Resultado do teste A/B - Adições ao Carrinho .....	36
Tabela 15 - Resultado do teste A/B - Transações.....	36
Tabela 16 - Relatório de Sessões .....	37
Tabela 17 - Resultado de teste A/B - Sessões engajadas .....	38
Tabela 18 – Relatório Agrupado.....	43
Tabela 19 - Resultado de teste A/B - Agrupado .....	43

## SUMÁRIO

<b>1. INTRODUÇÃO</b> .....	8
1.1. OBJETIVOS .....	10
1.1.1 Objetivo Geral.....	10
1.1.2 Objetivos Especificos .....	10
<b>2. REVISÃO TEÓRICA</b> .....	11
2.1 A INTELIGÊNCIA ARTIFICIAL NO EMAIL MARKETING.....	11
2.2. REGULAMENTAÇÃO DO EMAIL MARKETING .....	12
2.3 APLICAÇÕES ATUAIS .....	14
<b>3. METODOLOGIA</b> .....	19
3.1 CONTEXTO DE APLICAÇÃO.....	19
3.2 REVISÃO DE BOAS PRÁTICAS .....	20
3.3 COLETA DE DADOS.....	21
3.3.1. Variáveis dependentes .....	22
3.3.2 Variáveis independentes .....	22
3.3.3 Segmentação de usuários .....	22
3.3.4 Definição do uso do Einstein Recommendations .....	24
3.3.5 Template utilizado nas comunicações .....	26
3.3.6 Testes A/B.....	26
<b>4. ANÁLISE E APRESENTAÇÃO DOS RESULTADOS</b> .....	29
4.2 RESULTADOS DE ENGAJAMENTO.....	29
4.3 RESULTADOS DE CONVERSÃO PÓS CLIQUE .....	35
<b>5. DISCUSSÃO E CONCLUSÕES</b> .....	40
5.1 ENGAJAMENTO E CONVERSÃO .....	40
5.2 DIFERENÇA DE RESULTADOS ENTRE SEGMENTOS.....	40
5.2.1 Compradores Engajados (CE).....	41
5.5.2 Usuários Engajados (UE) .....	42
5.5.3 Novos Usuários (NU).....	42
5.5.4 Segmentos Agrupados .....	423
5.3 LIMITAÇÕES E OPORTUNIDADES.....	44
<b>REFERÊNCIAS</b> .....	45

## 1. INTRODUÇÃO

Ao longo dos anos, desde a popularização dos computadores pessoais que se iniciou nos anos 90, o e-mail marketing tem se consolidado como um canal essencial para empresas que desejam se comunicar de forma eficaz com seus clientes. Atualmente, o Marketing Digital possui um escopo mais amplo e a crescente demanda por personalização nos pontos de contato entre empresa e cliente colocou o e-mail marketing como um canal promissor quando se fala de relacionamento com o cliente e de vendas.

De acordo com Ugonna *et al.* (2017), o e-mail marketing é uma das estratégias de marketing digital utilizadas para enviar comunicações aos usuários no momento adequado para atender as necessidades dos clientes. Segundo Jain, *et.al* (2018), fornecer produtos e serviços aos clientes não funciona mais como uma experiência de compra online, no qual o método tradicional está desalinhado ao ambiente atual. Os varejistas precisam compreender e estudar o histórico de compras de produtos, de pesquisados, de adicionados ao carrinho e da lista de desejos de compras que podem aprimorar, assemelhar e complementar suas compras anteriores. Para tornar as compras online uma experiência de “bem-estar”, as empresas precisam conquistar clientes e fornecer uma experiência única, o varejista precisa se comunicar com o cliente em tempo real por meio de todos os canais e fornece comunicação personalizada usando dados históricos. Para atingir tais níveis de personalização, a Inteligência Artificial (IA) vem se tornando cada vez mais relevante no Marketing Digital e especialmente nos canais de e-mail.

Muitos são os desafios na implementação e adesão das recomendações de produtos através de IA. Para recomendações eficazes, de acordo com Gabrani, Sabharwal e Singh (2017) volumes monstruosos de dados precisam ser coletados, organizados e processados. Para ganhar escalabilidade nas recomendações, é necessário que haja uma infraestrutura robusta e, muitas vezes, custosa. Outro desafio comum é o “problema de inicialização a frio” como é chamado o desafio de fazer recomendações eficazes para novos usuários ou novos itens que ainda não possuem muitos dados históricos ou avaliações. O “problema da superespecialização” é o efeito causado pelo algoritmo que recomenda produtos de acordo com o perfil do usuário e faz com que novos produtos inesperados que podem ser interessantes não sejam recomendados com frequência. Além de todos esses desafios técnicos, ainda



existem outros desafios na adesão dos consumidores às recomendações como é o caso do “efeito palavra de máquina”, definido por Longoni e Cian (2020) e ao “efeito de aversão ao algoritmo”, como menciona Castelo, Bos e Lehmann (2019). Com o desenvolvimento constante da tecnologia, muitas dessas barreiras vão sendo aos poucos superadas e a popularização da IA como ferramenta de recomendação tende a crescer ainda mais.

Existe um consenso crescente entre os profissionais de e-mail marketing a respeito do significativo aumento do engajamento dos usuários e melhoria dos resultados das campanhas à medida que a personalização e a individualização das comunicações acontecem. A personalização de conteúdo tem sido bem-sucedida em muitas áreas, como por exemplo em sistemas de tutoria inteligentes que adaptam material educativo às preferências dos utilizadores (Almasri *et al.*, 2019); sistemas de recomendação (Murali, Vishnu e Victor, 2019); ou personalização de produtos em sistemas de comércio eletrônico (Zhao, 2019). Além disso, diversos estudos como Trespacios e Perkins (2016) demonstram a eficácia da personalização no canal de e-mail. De acordo com Bokde e Seshan (2019), para garantir o impacto do e-mail marketing e maximizar o engajamento, os e-mails devem ser personalizados e entenderem as necessidades, o momento e os interesses de cada usuário, baseado nas suas preferências e comportamento. Com o desenvolvimento da tecnologia, já é possível realizar todas essas personalizações utilizando modelos de recomendação de inteligência artificial (IA), como ressaltou Ludermir (2021, p. 2):

Os bons Sistemas de recomendação como o da Amazon (recomendação de livros e produtos em geral), Netflix (recomendação de filmes e séries), Spotify (recomendação de músicas) e muitos outros, também são consequências do avanço das técnicas de IA. Hoje as recomendações fornecidas por esses sistemas estão de acordo com as preferências dos usuários.

Sendo assim, uma boa recomendação de produtos personalizada é um fator que pode melhorar a satisfação do cliente e a relevância das ofertas.

No que diz respeito ao estado atual da pesquisa, Felfernig (2008) já destacou a importância da adesão às recomendações (de nada adianta recomendações certas se os consumidores não aderem a elas nos canais) e explorou alguns dos fatores que influenciam nessa adesão. Gürsoy (2019) destaca que os consumidores passam por um processo de geração de aceitação e que a influência social e a motivação hedônica estão positivamente relacionadas à adesão. Park (2022) destaca

a importância da credibilidade, qualidade e utilidade das recomendações e Sohn e Kwon (2020) enfatiza ainda o papel do prazer e das normas subjetivas na influência da intenção de compra do cliente. Por fim, há ainda uma discussão relacionada à ética no que se refere à coleta, armazenamento e processamento de dados de usuários. Green (2018) sublinha a importância de considerar uma vasta gama de preocupações éticas na IA incluindo transparência, preconceito e desigualdade socioeconômica. Todos esses fatores podem influenciar na adesão às recomendações de produtos. Mesmo com diversos estudos focados nas motivações para a adesão ou não de recomendações de IA, existem lacunas no que diz respeito especificamente ao e-mail marketing e também relacionados ao contexto brasileiro.

## 1.1. OBJETIVOS

A seção apresenta os objetivos do trabalho, divididos entre objetivo geral e objetivos específicos.

### 1.1.1 Objetivo Geral

Entender qual a eficácia e influência das comunicações de e-mail que possuem recomendações geradas por inteligência artificial em comparação com as que possuem recomendações genéricas baseados em dados gerais do site na taxa de conversão do e-commerce da Democrata Calçados.

### 1.1.2 Objetivos Específicos

- a) Levantar dados a partir de e-mails com personalizações de IA e de abordagens tradicionais
- b) Verificar elementos de divergência nas recomendações de IA e de abordagens tradicionais
- c) Analisar o comportamento de engajamento (abertura, clique e *opt-out*) dos assinantes nas comunicações de ambos os cenários
- d) Analisar o comportamento pós-clique (taxa de conversão) dos assinantes nas comunicações de ambos os cenários

## 2. REVISÃO TEÓRICA

O presente capítulo busca o esclarecimento dos conceitos utilizados na pesquisa, trazendo maior embasamento para o tema abordado através de contexto, abordando leis e limitando até onde os recursos atuais já evoluíram: de referências acadêmicas, com as principais pesquisas já realizadas e definições teóricas dos conceitos utilizados, e da elucidação do funcionamento das plataformas que dispõem dos recursos de inteligência no e-mail marketing.

### 2.1 A INTELIGÊNCIA ARTIFICIAL NO EMAIL MARKETING

A recomendação de produtos, por mais que tenha ganhado evidência com o surgimento de novas tecnologias de inteligência artificial como o Chat GPT, não é uma inovação recente. A Amazon já utilizava algoritmos de recomendação de produtos há mais de 20 anos, como mostra o estudo de Linden, Smith e York (2003).

Mais recentemente, o estudo de Bhagat e Chatur (2023) analisou e comparou a literatura existente sobre vários sistemas de recomendação de produtos incluindo filtragem colaborativa (CF), redes neurais (NM) e redes Bayesianas profundas (DBN). A filtragem colaborativa é uma técnica de recomendação que usa dados de compras anteriores, classificações de produtos e de outros atributos para identificar padrões e fazer previsões sobre quais produtos um cliente pode estar interessado. Esses modelos podem ser baseados em usuário (UBCF) ou baseado em item (IBCF). As redes neurais (NM) são um tipo de algoritmo de aprendizado de máquina que usa uma rede de neurônios artificiais para processar informações. As redes Bayesianas profundas (DBN) são um tipo de rede neural que usa camadas ocultas para aprender representações hierárquicas de dados.

A partir desse estudo, podemos perceber que os modelos de recomendação vêm evoluindo rapidamente e através de diversas abordagens diferentes. Com o crescente aumento na qualidade das recomendações, espera-se que haja impacto direto nas taxas de engajamento e de conversão dos canais que utilizam esses recursos.

A pesquisa “Improving Email Marketing Campaign Success Rate Using Personalization”, reforçou algo que hoje é certeza entre os profissionais de e-mail marketing: a personalização aumenta o engajamento do usuário em todos os níveis.

Mensagens e chamadas para ação personalizadas são mais abertas e mais clicadas. Formulários com atributos de personalização e assinaturas de pessoas de relevância para os usuários são mais respondidos, ofertas personalizadas geram mais compras e mais receita e o remetente, principalmente no caso de empresas, se torna mais relevante.<sup>1</sup>

Portanto, quanto mais dados dos usuários, sejam eles demográficos ou de comportamento, forem coletados, maior customização e relevância é possível atingir. Para disponibilizar produtos e serviços personalizados no canal de e-mail, as empresas precisam de dois tipos de informação: informações pessoais (como nome, dados demográficos e geográficos) e informações de preferências relativas a produtos.

No que se refere à personalização por meio de IA, podemos dividir os métodos a partir do tipo de feedback dos usuários, em feedback explícito e implícito (Prathama *et al.*, 2021). Recomendações baseadas em feedback explícito são recomendações conforme as preferências expressas diretamente pelos usuários, como avaliações, opiniões e dados demográficos preenchidos em formulários. Recomendações baseadas em feedback implícito são recomendações segundo as preferências ou tendências comportamentais indiretamente expressas pelos usuários, como histórico de compras, navegação e cliques (Chu e Park, 2009; Zhou e Han, 2019). Saber diferenciar os tipos de recomendação assim como os diferentes resultados obtidos por cada uma tem implicações teóricas e práticas importantes para obter uma compreensão mais profunda da tomada de decisão dos consumidores na hora da compra e promover o desenvolvimento de recomendações de IA.

## 2.2. REGULAMENTAÇÃO DO EMAIL MARKETING

A coleta e tratamento de dados de usuários, assim como do envio de comunicações promocionais através do canal de e-mail, estão sujeitos a diversas leis ao redor do mundo, inclusive no Brasil.

A prática do Email Marketing no Brasil, principalmente quando se utiliza de personalização, necessita do tratamento de dados e, portanto, as empresas estão

---

<sup>1</sup> SINGH, Gyanendra.; SINGH, Himanshu.; SHRIWASTAV, Sonika. Improving Email Marketing Campaign Success Rate Using Personalization. *Advances in Analytics and Applications*. Springer Proceedings in Business and Economics, *In*: LANA, Arnab Kumar (ed). **Advances in Analytics and Applications**. Singapura: Springer, 2018. p. 77-83.

sujeitas a Lei nº 13.709/18 conhecida como Lei Geral de Proteção de Dados (LGPD). A LGPD define tratamento de dados como “acesso, armazenamento, arquivamento, avaliação, classificação, coleta, difusão, distribuição, eliminação, extração, modificação, processamento, produção, recepção, reprodução, transferência, transmissão ou utilização de dados” (Brasil, 2018).<sup>2</sup> A LGPD surgiu no Brasil para garantir a privacidade do usuário e regulamentar, entre outras práticas, o Email Marketing a respeito do que foi a o CAN-SPAM (Controlling the Assault of Non-Solicited Pornography And Marketing) nos Estados Unidos em 2003 e a GDPR (General Data Protection Regulation) na União Europeia em 2016.

Apesar das leis que regulam a prática do e-mail marketing, ainda há muitos pontos de debate a respeito do tema. Um exemplo clássico diz respeito aos limites da personalização. Qual é o ponto em que o uso dos dados pessoais e comportamentais deixa de ser um incentivo e se torna um desconforto para o usuário. O canal de e-mail nesse contexto, “busca criar vínculo, oferecer periodicidade e atingir um público específico na relação comercial, objetivando a satisfação dos consumidores” (Bernardes, 2009, p. 31). Nesse sentido, causar desconforto no usuário é extremamente contrário ao objetivo final.

O excesso de personalização não é o único ponto de atenção. Como diz Timponi (2022, p. 58):

A alta frequência de mensagens é mais prejudicial do que a personalização em si. Apesar de não causar uma interrupção abrupta do relacionamento entre cliente e marca, pode causar momentos de irritação, que, a longo prazo, geram insatisfação e substituição no processo de compra.

Por isso, é importante que a construção do relacionamento seja respeitosa e gradual observando práticas importantes:

- O consentimento do usuário, isto é, a declaração explícita do interesse em receber comunicações. O consentimento ou *opt-in* pode ser realizado digitalmente através de um botão com frases como “quero receber comunicações promocionais” em formulários, compras ou cadastros ou presencialmente, através de formulários em eventos ou

---

<sup>2</sup> BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Institui a Lei Geral de Proteção de Dados (LGPD). Brasília, DF: Presidência da República, 2018. Disponível em: < <https://bit.ly/3UzYJT5>>. Acesso em: 8 out. 2023.

fichas de cadastro em papel físico. Ao realizar o *opt-in*, o usuário se torna um assinante.

- A frequência dos disparos de e-mail que deve observar um período entre uma mensagem e outra para que o usuário se mantenha ativo e engajado e não se descadastre por estar recebendo muitas mensagens. Esse período varia de acordo com a base e, portanto, é necessário observar o histórico dos usuários para encontrar o período mais assertivo.
- Os *layouts* das comunicações devem ser responsivos, ou seja, devem se adaptar de acordo com as telas em que serão exibidos (*mobile, desktop, tablets, etc.*). Dessa forma, evita-se a frustração do usuário de abrir um e-mail em seu celular e não conseguir visualizar o conteúdo por estar dividido em várias colunas e muito pequeno para a leitura confortável.
- Os pedidos de *opt-out* devem ser honrados. Isto é, quando um usuário não quiser mais receber comunicações, ele deve estar apto a se desinscrever em poucos cliques e o remetente deve respeitar esse desejo e não enviar mais e-mails até que o usuário sinalize o desejo contrário.

## 2.3 APLICAÇÕES ATUAIS

Desde 2017, os grandes fornecedores de tecnologia de e-mail marketing começaram a investir em soluções de Inteligência Artificial. A empresa Salesforce por exemplo, líder no setor, desenvolveu o “*Einstein*” inteligência artificial que permite incrementar a operação de e-mail. A IA estuda continuamente os dados de envio, possibilitando ações como o envio no horário com a maior probabilidade de engajamento e auxilia o operador da plataforma a encontrar a frequência ideal que mantém o usuário ativo sem desgastá-lo.

Atualmente com o Chat GPT, muitas outras soluções estão surgindo para diversas outras plataformas como o Hubspot, o Microsoft Dynamics e a Oracle Responsys. O Salesforce Marketing Cloud Einstein é uma das inteligências artificiais mais utilizadas no ramo do e-mail marketing e principalmente quando se fala de e-commerces. A tecnologia monitora o comportamento dos usuários no site e

recomenda produtos baseando-se nos dados coletados. O Einstein é conectado com o catálogo de produtos do site que armazena dados e metadados a respeito dos produtos. Baseado nos dados coletados, o Einstein é capaz de realizar dois tipos de recomendação: *web recommendations* e *email recommendations*. O primeiro é a recomendação de conteúdos em blog e o segundo é a recomendação de produtos no e-mail.

Akimova (2019) salientou que o mais importante para a recomendação do Einstein é a lógica. Quando há dados suficientes, como histórico de compras, de navegação no site e afinidade com os produtos, é possível fazer recomendações mais certas. Enquanto para usuários que não possuem tantos dados disponíveis, o Einstein utiliza um recurso chamado *wisdom of the crowd* que nada mais é do que utilizar as recomendações mais populares para grupos em que a coleta de dados não foi suficiente para a IA fazer uma recomendação personalizada. Ainda é possível utilizar uma árvore de decisão pré-definida para atender aos usuários com poucos dados disponíveis. As recomendações disponíveis no *Einstein Email Recommendations* estão divididas em três classes: cenários de itens de referência, cenários de dados de usuários e cenários de dados do site.

Os cenários de itens de referência exigem um ou mais itens de referência específicos, por exemplo, o usuário comprou o item X ou algum item da categoria Y. Esse item ou essa categoria servirá de referência para a recomendação de novos produtos. Os cenários de itens de referência disponíveis estão descritos na Tabela 1:

Tabela 1 - Cenários que exigem um parâmetro de item ou categoria para a recomendação de produtos

CENÁRIO	DESCRIÇÃO
Comprou - Comprou	Usuários que compraram o item X também compraram esses itens.
Comprou - Comprou Mesclado	Usuários que compraram algum dos itens do carrinho também compraram esses itens.
Clicou - Comprou	Usuários que clicaram no item X também compraram esses itens.
Visualizou Categoria - Comprou	Usuários que visualizaram um item da categoria X também compraram esses itens.
Visualizou Categoria	Usuários que visualizaram um item da categoria X também visualizaram esses itens.

Buscou - Comprou	Usuários que usaram o termo de pesquisa X compraram esses itens.
Buscou - Visualizou	Usuários que usaram o termo de pesquisa X visualizaram esses itens.
Tag	O item mais popular com base em compras, cliques ou visualizações da categoria X.
Tag - Intersecção	Itens mais populares com uma interseção de atributos que correspondem aos atributos do valor do parâmetro do item visualizado pelo usuário.
Tag Recentes	Itens recentemente disponíveis da categoria X.
Tag Visualizados e Comprados	Itens mais visualizados e comprados da categoria X.
Tag Melhores Avaliações	Item mais bem avaliado da categoria X
Visualizou – Comprou	Usuários visualizaram o item X também compraram esses itens.
Visualizou - Visualizou	Usuários que visualizaram o item X também visualizaram esses itens.
Visualizou – Visualizou Mesclado	Usuários que visualizaram qualquer um dos itens do carrinho também visualizaram esses itens.

Fonte: Salesforce (2023).<sup>3</sup>

Os cenários de dados de usuários disponíveis estão descritos na Tabela 2.

Tabela 2 - Cenários baseados no perfil de Inteligência Preditiva do usuário e no comportamento pessoal do site

CENÁRIO	DESCRIÇÃO
Comprou – Comprou Último Carrinho	Usuários que compraram o último item adicionado ao carrinho também compraram esses itens.
Comprou – Comprou Última Compra	Usuários que compraram o último item comprado também compraram esses itens.
Tag – Afinidade	Itens mais populares com atributos que correspondem ao interesse do assinante ou visitante com base no seu perfil de afinidade. Essas recomendações são baseadas na maior afinidade do usuário. Retorna os itens mais populares que correspondem à única tag superior em seu gráfico de afinidade ponderada.

<sup>3</sup> Einstein Recommendations Scenarios. **Salesforce**. Disponível em: <<https://bit.ly/3ujID5D>>. Acesso em: 7 out. 2023.



Últimas Visualizações Mesclado	Usuários que visualizaram qualquer um dos últimos 7 itens visualizados por este assinante ou visitante também visualizaram esses itens.
Visualizado Recentemente	Qualquer um dos últimos 7 itens visualizados pelo assinante ou visitante.
Afinidades do usuário	Recomendações baseadas no perfil completo de afinidade do usuário. Retorna itens que correspondem às cinco principais afinidades listadas no perfil de contato, com base em compras, cliques e visualizações ao longo do tempo. É dada preferência a itens marcados com vários atributos nas cinco principais listas de afinidades.
Visualizou - Comprou Último Carrinho	Usuários que visualizaram este item em um carrinho também compraram esses itens.
Visualizou – Comprou Última Compra	Usuários que visualizaram o último item comprado por esse usuário também compraram esses itens.
Visualizou – Visualizou Último Carrinho	Usuários que visualizaram este item no carrinho também visualizaram esses itens.
Visualizou – Visualizou Última Compra	Usuários que visualizaram o último item comprado pelo usuário também visualizaram esses itens.

Fonte: Salesforce (2023).<sup>4</sup>

Os cenários de dados do site disponíveis estão descritos na Tabela 3.

Tabela 3 - Cenários baseados no comportamento agregado coletado do site.

Nenhuma informação é personalizada no nível do usuário.

CENÁRIO	DESCRIÇÃO
Novos Lançamentos	Essas informações incluem 100 itens no site onde o parâmetro ReleaseDate está nos últimos 14 dias. Os valores são classificados pela data mais recente.
Mais Populares	Produtos mais populares no site com base em uma combinação de itens visualizados e comprados.
Maiores Geradores de Receita	Itens de maior bilheteria em termos de receita total gerada.

<sup>4</sup> Einstein Recommendations Scenarios. **Salesforce**. Disponível em: <<https://bit.ly/3ujID5D>>. Acesso em: 7 out. 2023.

Mais Vendidos	Produtos mais vendidos no site com base nas unidades vendidas.
Mais Visualizados	Até 100 dos itens mais vistos no site.

Fonte: Salesforce (2023).<sup>5</sup>

---

<sup>5</sup> Einstein Recommendations Scenarios. **Salesforce**. Disponível em: <<https://bit.ly/3ujID5D>>. Acesso em: 7 out. 2023.

### 3. METODOLOGIA

Nesta seção, apresentaremos uma descrição dos procedimentos metodológicos para a condução do estudo comparativo entre as abordagens de recomendação por Inteligência Artificial (IA) e por seres humanos através da ferramenta Salesforce Marketing Cloud.

#### 3.1 CONTEXTO DE APLICAÇÃO

Ao longo dos anos, a Democrata Calçados tem expandido sua linha de produtos, oferecendo uma ampla variedade de estilos que vão desde sapatos sociais e casuais até botas e acessórios masculinos. Essa diversificação estratégica permitiu que a empresa atendesse às diferentes demandas e preferências dos consumidores, estabelecendo-se como uma marca completa e versátil para o universo masculino. Mais recentemente, a partir de 2020, a empresa começou a desenvolver o seu e-commerce, cujo crescimento foi alavancado pela pandemia e pelas estratégias de Marketing Digital, entre elas, a estratégia de E-mail Marketing.

A operação de E-mail Marketing começou de forma bem discreta, com pouca participação nos resultados e uma plataforma sem muitos recursos. Com o passar do tempo, a base de contatos foi crescendo, a relevância do canal foi se tornando maior e o tempo e dinheiro investido também.

Atualmente, a Democrata possui uma ferramenta com uma ampla coleta de dados de engajamento nos e-mails e no site, uma base de usuários com mais de 100.000 contatos e canais de e-mail, SMS e Whatsapp ativos com uma ferramenta de inteligência artificial chamada *Einstein Recommendations* que é alimentada com todos esses dados para sugerir qual o melhor produto do catálogo para cada assinante. A Democrata vê na recomendação personalizada de produtos uma forma de aumentar o volume de transações e a receita do canal. Nesse momento, a empresa busca entender se o investimento em ferramentas de inteligência artificial é justificado com acréscimo na taxa de conversão.

O Einstein é a inteligência artificial do Salesforce Marketing Cloud. Através dela, a ferramenta coleta informações ao nível de usuário que possibilitam definir melhor horário de disparo, textos e imagens que mais engajam o público, personas com base na interação do usuário, entre outras informações relevantes.

Para trazer informações do cliente e fornecer dados sobre a navegação do usuário, o marketing cloud utiliza-se de *snippets* inseridos no código do site para captar interações a nível de produtos como, por exemplo, visualização de páginas, compras de produtos, carrinho abandonado e adição aos favoritos. Por meio dos dados coletados a ferramenta pode criar vitrines personalizadas conforme o comportamento de cada usuário utilizando os cenários descritos anteriormente.

No caso da Democrata, com o Einstein já implementado, as ferramentas de personalização se tornam acessíveis no dia a dia, visto que podem ser realizadas em massa sem um grande investimento de tempo e equipe. Isso por si só já é suficiente para um incremento nos resultados da empresa. Jones (2015) afirma que a personalização é um fator-chave no processo de compra, uma vez que aumenta resultados de cliques, taxas de abertura e conversão. Além disso, 78% dos respondentes disseram que comunicações personalizadas aumentam sua chance de compra e 75% afirmaram que comunicações personalizadas são fundamentais no processo decisório.<sup>6</sup>

Com isso, conclui-se que a personalização realizada por inteligência artificial tende a trazer um incremento nas métricas chaves de engajamento e conversão, uma vez que possibilita a personalização em comunicações que não seriam personalizadas sem esses recursos. O presente estudo busca suprir algumas lacunas na bibliografia existente, uma vez que restam dúvidas a respeito da eficácia e a influência da personalização da IA em comparação à recomendação tradicional quando se trata de taxas de conversão no e-commerce brasileiro.

### 3.2 REVISÃO DE BOAS PRÁTICAS

Para que possamos avaliar a influência das recomendações personalizadas por IA na taxa de conversão do e-mail marketing de Democrata, é preciso definir uma série de conceitos importantes no universo do e-mail marketing. Para realizar a comparação entre os dois grupos (usuários impactados por e-mails personalizados por abordagens tradicionais e usuários impactados por e-mails personalizados por inteligência artificial) será necessário segmentar a base de usuários em subgrupos menores.

---

<sup>6</sup> The value of getting personalization right—or wrong—is multiplying. **McKinsey&Company [online]**. 12 nov. 2021. Disponível em < <https://bit.ly/3urBIY4> > Acesso em 12 ago. 2023.

Assim, trazendo o conceito para o contexto do estudo, utilizaremos uma série de segmentações diferentes para trazer maior diversidade de pontos de vista. Alguns exemplos de segmentações utilizadas no caso da Democrata são: usuários compradores (todos aqueles assinantes que já realizaram ao menos uma compra), usuários não-compradores (todos aqueles assinantes que ainda não realizaram nenhuma compra), usuários com interesse em botas (todos aqueles assinantes que navegaram na sessão de botas do site), usuários desengajados (todos aqueles assinantes que não interagem com comunicações há mais de 90 dias), usuários de alto ticket médio (todos aqueles assinantes que fizeram compras de mais de R\$1.000,00). É possível criar segmentações com todos os dados disponíveis e, inclusive, cruzar dados para criar segmentos ainda mais restritos, como por exemplo usuários não compradores com interesse em botas.

Outro conceito chave do estudo é o engajamento. A boa prática do e-mail marketing é considerar como usuário engajado, todo assinante que abriu ou clicou em algum e-mail nos últimos 90 dias. Baseado na definição de Baumgarten (2021), a abertura do e-mail é contabilizada pelas plataformas de E-mail Marketing quando o usuário clica na mensagem na caixa de entrada e os textos ou imagens são carregados. O clique é contabilizado quando o usuário clica em algum dos *links*, botões ou imagens do e-mail. As taxas de abertura estão muito relacionadas com o assunto utilizado no e-mail enquanto a taxa de clique está ligada ao *layout* e as informações contidas na mensagem.

No contexto do estudo, uma vez que o que será personalizado é o conteúdo do e-mail (produto oferecido), espera-se que as principais diferenças sejam observadas nas taxas de cliques e taxas de conversão (quando o usuário realiza a compra no site a partir de um e-mail enviado).

No E-mail Marketing, o modelo mais utilizado para validar hipóteses e entender o comportamento da base de usuários é o teste A/B. Para Neves e Duduchi (2019), o conceito de teste A/B é definido como um experimento controlado onde os usuários são divididos de maneira aleatória em subgrupos e expostos a diferentes experiências para analisar suas respostas. Previamente, são definidas as métricas que serão utilizadas para avaliar qual das experiências tem o melhor desempenho.

### 3.3 COLETA DE DADOS

Todos os dados foram coletados a partir de disparos de e-mail na plataforma Salesforce Marketing Cloud da Democrata Calçados. As bases utilizadas para as segmentações e envios foram criadas a partir da base de assinantes da empresa com aproximadamente 150 mil usuários. Para esse estudo, pensando em manter o volume normal de disparos mensais já realizados pela equipe da Democrata, foram utilizados apenas 20 mil contatos.

### 3.3.1. Variáveis dependentes

As variáveis dependentes do experimento são:

- Engajamento por Tipo de Recomendação: comparação das taxas de abertura, cliques e *opt-out* entre as recomendações de IA e abordagens humanas.
- Conversão Pós-Clique por Tipo de Recomendação: avaliação das taxas de conversão após interações com os produtos recomendados nos dois cenários.
- Análise Incremental: determinar a partir de qual quantidade de dados a IA começa a gerar recomendações relevantes e de maior impacto.

### 3.3.2 Variáveis independentes

As variáveis independentes do experimento são:

- Segmentações: as bases segmentadas de acordo com histórico de engajamento utilizadas para cada um dos disparos
- Tipo de recomendação: se o e-mail foi enviado com recomendações personalizadas com base no algoritmo de inteligência artificial ou utilizando de recomendações tradicionais

### 3.3.3 Segmentação de usuários

Antes dos envios iniciarem, foi realizado um processo de segmentação dos usuários. Como foi necessário limitar a base total do experimento para 20 mil contatos, as segmentações foram recortes que buscavam representar tanto novos usuários como antigos e olhar tanto para bases compradoras como para bases que até o momento, apenas interagiram com as comunicações. Essas informações de histórico de compra e de tempo na base são critérios importantes para a qualidade das recomendações de IA.

As segmentações foram baseadas em critérios de compra, engajamento e entrada na base. Os usuários foram divididos em três grupos diferentes, definidos como “compradores engajados” - usuários que abriram pelo menos uma comunicação nos últimos 90 dias e já compraram algum produto no site, “usuários engajados” - usuários que abriram pelo menos uma comunicação nos últimos 90 dias e nunca compraram no site e “novos usuários” - usuários que entraram na base nos últimos 30 dias e nunca compraram no site.

A base “compradores engajados” possui 42.898 usuários de onde utilizamos 6.650 usuários selecionados de forma aleatória; a base “usuários engajados” possui 52.988 usuários de onde utilizamos 6.650 usuários selecionados de forma aleatória; a base “novos usuários” tem 8.204 usuários de onde utilizamos 6.650 usuários selecionados de forma aleatória.

Além das informações a respeito do histórico de engajamento e compras das bases, há poucas informações disponíveis para realizar uma análise descritiva. Sabe-se, contudo, que a base é totalmente composta por homens. Além disso, é possível inferir, por amostragem, que a base possui cerca de 33% do usuários no estado de São Paulo, 9% em Minas Gerais, 9% no Rio de Janeiro, 9% no Paraná e 8% no Rio Grande do Sul. Os 32% restantes divididos no restante do país.

Em relação ao engajamento dos usuários, podemos entender a média de aberturas, cliques e compras de cada base na tabela 4

Tabela 4 – Comportamento da base

Segmentação	Média de Aberturas	Média de Cliques	Média de Compras
CE	35,49	2,46	1,47
UE	40,09	2,15	0
NU	3,42	0,37	0

Fonte: autor (2024).

Com isso podemos esperar taxas de aberturas e cliques maiores nas bases de Usuários Engajados e Compradores engajados.

### 3.3.4 Definição do uso do Einstein Recommendations

Para esse estudo, utilizamos duas diferentes lógicas de recomendação: uma baseada em inteligência artificial como preferências do usuário e perfis de consumo parecidos e outra baseada em uma abordagem tradicional, considerando regras gerais do site como produtos mais vendidos e lançamentos recentes. As recomendações de inteligência artificial irão obedecer às ordens de cenários estipulados abaixo (Figura 1).

Figura 1- Ordem de cenários da recomendação de Inteligência Artificial

☰	User Affinities	✕
☰	Bought Bought	✕
☰	Bought Bought Last Purchase	✕
☰	Bought Bought Last Cart	✕
☰	Last Views Merge	✕
☰	View View Last Cart	✕
☰	Top Grossing	✕

Fonte: Salesforce Marketing Cloud (2023).

Isso quer dizer que para os usuários impactados pela comunicação com recomendações de produtos por inteligência artificial serão exibidos produtos recomendados por Afinidades do Usuário, definido na Tabela 2. A forma como os critérios de afinidade são definidos não é totalmente clara, mas é possível perceber alguns padrões dentro da plataforma a partir a partir do comportamento do usuário. Se um usuário visita ou compra muitos produtos da mesma cor, por exemplo, a cor passa a ter um peso maior no perfil de afinidade do usuário pois a IA entende que esse é um fator relevante. Outros fatores que são frequentemente sensíveis nos critérios de recomendação são categoria (como sapatos, botas, tênis, cintos, mochilas...) e faixa de preço.



Como nem todos os usuários possuem um histórico de navegação, compras e preferências, a IA pode não conseguir traçar um perfil. Nesse caso, os produtos passam a ser exibidos conforme a ordem da cascata da Figura 1. A recomendação seguinte é a Comprou - Comprou, definida na Tabela 1. Caso o usuário não tenha um histórico suficientemente completo, passa para os itens abaixo da ordem. Nesse experimento, a IA faz todas as 4 recomendações com base no primeiro critério. Isso é, não foi necessário utilizar o modelo de cascata.

Em relação às recomendações tradicionais, respeitarão a ordem de exibição da Figura 2.

Figura 2 - Ordem de cenários da recomendação padrão

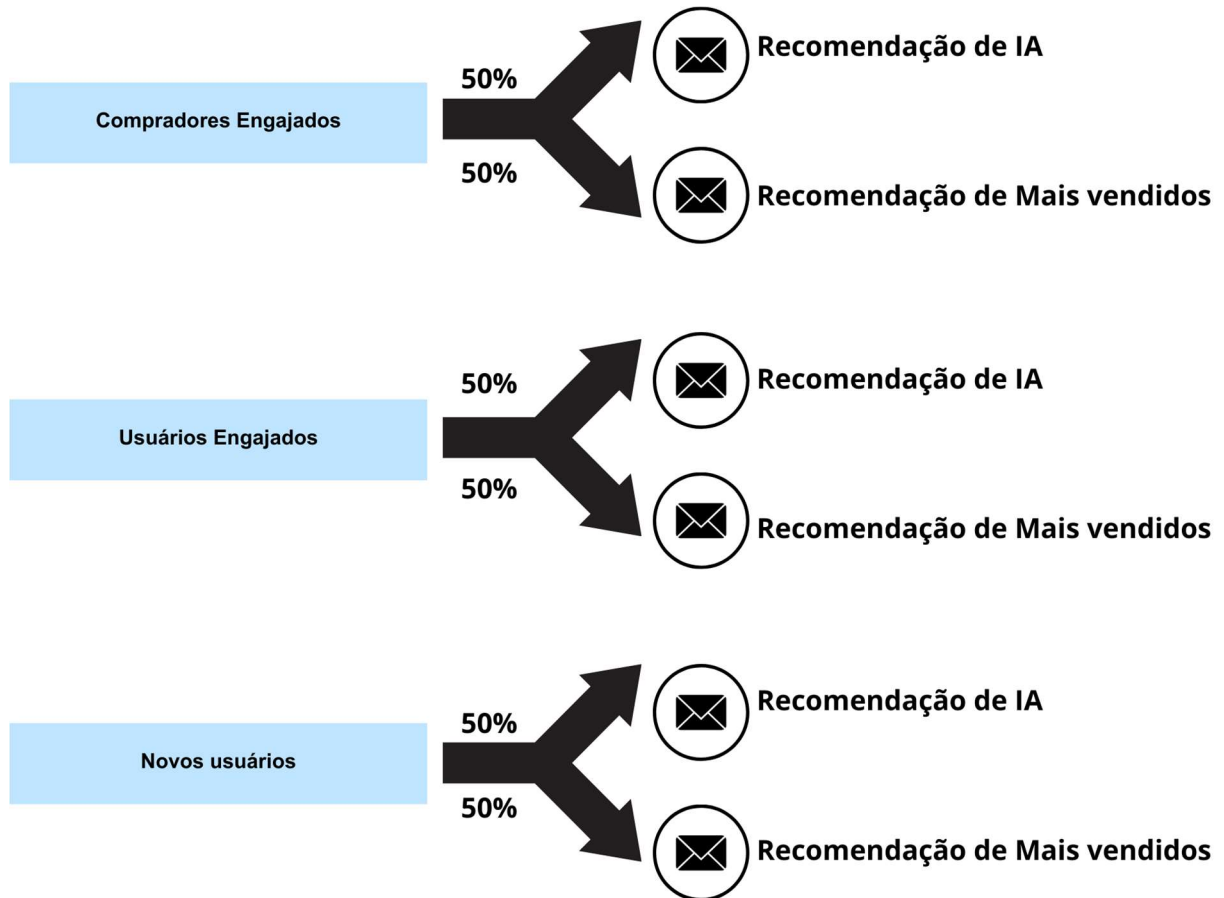


Fonte: Salesforce Marketing Cloud (2023).

Isso quer dizer que os usuários receberão primeiro recomendação de produtos mais vendidos do site (Mais vendidos, definido na Tabela 3). Se não houver histórico suficiente, segue a cascata pré-estipulada. Nesse formato de recomendação, nenhuma informação do usuário é utilizada. Somente histórico geral do site. Para esse estudo, todas as comunicações sejam elas com recomendação de IA ou com recomendação tradicional possuem quatro produtos recomendados sendo exibidos.

O fluxo de disparos acontece a partir da seguinte lógica: os usuários serão divididos conforme a sua segmentação (compradores engajados, usuários engajados e novos usuários). Em seguida, serão divididos de forma igualitária (50% - 50%) aleatoriamente de modo que metade da base irá receber o e-mail com as recomendações de IA e a outra metade irá receber as recomendações genéricas. A Figura 3 exemplifica o fluxo.

Figura 3 - Fluxo do usuário para o recebimento do e-mail



Fonte: autor (2023).

Todos os usuários entraram no fluxo a partir da *Data Extension* representada no canto superior esquerdo da figura. Em seguida os usuários foram agrupados na sua respectiva segmentação (compradores engajados, usuários engajados e novos usuários) por meio da atividade *Decision Split* representada pelo sinal “?”. Em cada um dos grupos, as segmentações foram divididas aleatoriamente entre os usuários que receberam o e-mail com recomendação de IA e com recomendação tradicional. A partir disso, os dados de engajamento foram coletados no Salesforce Marketing Cloud e os dados de conversão foram coletados no Google Analytics.

### 3.3.5 Template utilizado nas comunicações

O *layout* e o assunto utilizado nas comunicações foi o mesmo para todos os segmentos e categorias de envio. Além disso, todos os disparos aconteceram ao mesmo tempo. A única diferença entre os e-mails são os produtos exibidos para cada usuário, de acordo com o seu perfil. O intuito dessa prática é comparar o impacto

apenas dos produtos exibidos sem a interferência de outras variáveis. O *layout* utilizado está colocado a seguir (Figura 4), exibindo produtos aleatórios somente para ilustrar o conteúdo do e-mail.

Além disso, pensando em manter o padrão dos emails já enviados pela Democrata, foi utilizado um banner principal estático com a figura de um modelo utilizando um tênis. Essa figura não varia de acordo com as recomendações e pode influenciar nos resultados da pesquisa contudo, avaliei os ganhos em manter o padrão dos emails maiores do que as perdas por conta desse banner principal.

Figura 4 - Template utilizado nos disparos



Fonte: autor (2023).

### 3.3.6 Testes A/B

Para realizar as análises, cada conjunto de segmentos como um teste A/B. O teste A/B é uma técnica estatística utilizada para comparar dois grupos - neste caso as recomendações de IA e as recomendações de produtos mais vendidos do site. Cada segmento foi dividido em duas partes, formando pares de teste A/B. O objetivo

do teste A/B é determinar se há uma diferença significativa entre os dois grupos em termos de uma métrica específica, como a taxa de conversão. Neste experimento, analisamos as taxas de abertura, cliques, cliques em recomendações, descadastrados, adições ao carrinho, transações e sessões engajadas.

O teste A/B frequentista é baseado na inferência estatística clássica. Ele utiliza um nível de confiança de 95%, o que significa que se o teste fosse repetido 100 vezes, esperaríamos que o resultado estivesse dentro do intervalo de confiança em 95 dessas vezes. O teste é bicaudal, o que significa que estamos interessados em detectar uma diferença em qualquer direção, seja a IA superando as recomendações de produtos mais vendidos ou vice-versa.

O teste começa com a hipótese nula que afirma que não há diferença entre os dois grupos. Em seguida, os dados são coletados e a diferença entre as médias dos grupos é calculada. Se essa diferença for grande o suficiente para ser improvável de ocorrer por acaso (dado o nível de confiança), então a hipótese nula é rejeitada em favor da hipótese alternativa que afirma que há uma diferença entre os grupos.

É importante notar que o teste A/B frequentista só pode dizer se há uma diferença entre os grupos, mas não pode quantificar o tamanho dessa diferença ou se ela é relevante na prática. Para isso, outras técnicas, como análise bayesiana, podem ser usadas.

## 4. ANÁLISE E APRESENTAÇÃO DOS RESULTADOS

Essa seção busca apresentar os resultados obtidos ao longo do experimento, respondendo aos objetivos geral e específicos. A análise dos dados coletados proporcionou *insights* a respeito do comportamento do consumidor da Democrata Calçados nos canais de e-mail marketing e das funcionalidades e limitações da recomendação de produtos por IA.

Para o capítulo de resultados, foram analisados e apresentados os resultados obtidos a partir do disparo de 19.950 e-mails buscando o entendimento do impacto da recomendação de produtos personalizada por inteligência artificial em comparação com a recomendação padrão de produtos mais vendidos no site nas taxas de clique e taxas de conversão.

### 4.1 RESULTADOS DE ENGAJAMENTO

Os disparos foram programados para acontecer no dia 25 de janeiro de 2024 às 10 horas. A base de 19.950 pessoas era composta por 6.650 usuários classificados como “CE - Compradores Engajados”, por 6.650 usuários classificados como “UE - Usuários Engajados” e por 6.650 usuários classificados como “NU - Novos Usuários”. Dentro de cada uma dessas segmentações, cada usuário possui 50% de chance de receber um e-mail personalizado com os produtos mais vendidos do site (Versão A) e 50% de chance de receber um e-mail personalizado com os produtos recomendados pela Inteligência artificial (Versão B).

Apesar de utilizar de critérios distintos para a recomendação, foi comum ver nas recomendações de IA, produtos que também estavam nas recomendações de mais vendidos do site. Isso se dá porque os produtos mais vendidos contribuem mais com dados para a IA do que produtos que os que não são tão vendidos. Esse fenômeno foi observado na literatura e ocorre frequentemente em casos onde o catálogo de produtos é extenso. Quanto mais produtos no catálogo, mais difícil é a recomendação e aqueles produtos que não tem tanto fluxo, acabam por ser menos recomendados.

Os disparos e as taxas de entrega ocorreram da seguinte forma.

Tabela 5 - Relatório de entregas

Segmento	Recomendação	E-mails enviados	E-mails entregues	Taxa de entrega
A – CE	Mais vendidos	3.322	3.319	99,91%
B – CE	Inteligência Artificial	3.317	3.317	100,0%
A – EU	Mais vendidos	3.331	3.329	99,94%
B – EU	Inteligência Artificial	3.308	3.305	99,91%
A – NU	Mais vendidos	3.256	3.253	99,91%
B – NU	Inteligência Artificial	3.378	3.375	99,91%

Fonte: autor (2023).

A taxa de entrega é uma variável que não sofre impacto das recomendações ou do conteúdo do e-mail. Os e-mails não entregues são eventos normais no universo do e-mail marketing e podem ocorrer por diversas razões como caixa de entrada cheia, instabilidade no provedor de e-mails, endereço de e-mail incorreto ou má reputação do remetente perante os provedores. As taxas de entrega ficaram muito parecidas entre as diferentes segmentações e apresentaram números saudáveis. As taxas de abertura são mostradas a seguir.

Tabela 6 - Relatório de aberturas

Segmento	Recomendação	Aberturas	Aberturas Únicas	Taxa de abertura
A - CE	Mais vendidos	1.653	1.356	40,86%
B - CE	Inteligência Artificial	1.704	1.393	42,00%
A - UE	Mais vendidos	1.633	1.396	41,93%
B - UE	Inteligência Artificial	1.696	1.424	43,09%
A - NU	Mais vendidos	581	479	14,72%
B - NU	Inteligência Artificial	602	480	14,22%

Fonte: autor (2023).

As taxas de abertura são influenciadas por diversos fatores. Os principais deles são o assunto do e-mail e o horário do disparo. Nesse experimento, utilizamos o mesmo assunto para todos os disparos e eles ocorreram às 10 horas da manhã, que é o horário habitual de disparo da Democrata. Assim, não há razões para que haja diferença significativa nas taxas de abertura dentro de uma mesma segmentação. Podemos notar, como era de se esperar, que as bases de usuários engajados (CE e UE) tiveram uma taxa de abertura muito maior do que o de novos usuários, que entraram recentemente na base e não possuem necessariamente um histórico de abertura na qual ainda não estão inseridos na rotina padrão de disparos. Como era previsto, não existem diferenças significativas nas taxas dentro de uma mesma segmentação como demonstrado na tabela abaixo.

Tabela 7 - Resultado do teste A/B - Aberturas

Segmentação	Abertura de A	Abertura de B	Aumento Relativo da taxa de Abertura	p-valor	Diferença Significativa
CE	40,86%	42,00%	2,79%	0,3458	Não
EU	41,93%	43,09%	2,75%	0,3427	Não
NU	14,72%	14,22%	-3,41%	0,5610	Não

Fonte: autor (2023).

Esses eram os resultados esperados até o momento. As taxas de clique são apresentadas a seguir.

Tabela 8 - Relatório de Cliques

Segmento	Recomendação	Cliques	Cliques únicos	Cliques em recomendações	Taxa de cliques em recomendações	Taxa de cliques	CTOR
A - CE	Mais vendidos	145	93	68	46,89%	2,80%	6,86%
B - CE	IA	176	105	92	52,27%	3,17%	7,54%
A - UE	Mais vendidos	110	59	52	47,27%	1,77%	4,23%
B - UE	IA	92	72	57	61,95%	2,18%	5,06%
A - NU	Mais vendidos	103	51	38	36,89%	1,57%	10,65%
B - NU	IA	117	57	52	44,44%	1,69%	11,88%

Fonte: autor (2023).

As taxas de clique são muito influenciadas pelo conteúdo do e-mail e nesta etapa que o impacto das recomendações começa a ser sentido. De cara, algumas coisas chamam a atenção como o fato de o CTOR (Taxa de cliques sobre aberturas) para a base de novos usuários ter sido maior do que das outras bases mesmo tendo o menor CTR (Taxa de cliques sobre entregues) e sendo, a princípio, uma base menos engajada. Esses dados nos mostram que apesar de ser uma base que engaja menos e abre menos e-mails, aqueles poucos usuários que se interessam pela comunicação, se interessam mais do que os dos outros segmentos que possuem um alto volume abertura nos e-mails, mas cujos participantes não costumam clicar nos produtos para ser direcionado ao site com tanta frequência.

Além disso, como podemos ver nas tabelas abaixo, não há diferenças significativas entre as versões do e-mail quando olhamos para a taxa de cliques sobre aberturas em nenhum dos segmentos. Quando isolamos os cliques realizados somente nas recomendações, podemos perceber que há um bom aumento relativo, porém, ainda sem diferença significativa.



Tabela 9 - Resultado do teste A/B - CTOR

Segmentação	CTOR de A	CTOR de B	Aumento Relativo do CTOR	p-valor	Diferença Significativa
CE	6,86%	7,54%	9,90%	0,4907	Não
EU	4,23%	5,06	19,63%	0,2942	Não
NU	10,65%	11,88%	11,53%	0,5475	Não

Fonte: autor (2023).

Tabela 10 - Resultados do teste A/B - Cliques em Recomendações

Segmentação	Taxa de clique nas recomendações de A	Taxa de clique nas recomendações de B	Aumento Relativo da taxa de cliques nas recomendações	p-valor	Diferença Significativa
CE	5,01%	6,60%	31,70%	0,0744	Não
EU	3,72%	4,00%	7,46%	0,7018	Não
NU	7,93%	10,83%	36,56%	0,1231	Não

Fonte: autor (2023).

Se olharmos com atenção para a segmentação de CE, podemos observar um resultado interessante. O p-valor desse teste é menor que os demais atingindo certa relevância estatística, apesar de não possuir 95% de confiança, critério utilizado nos testes. De qualquer forma, é legal observar esse resultado uma vez que a segmentação de CE é a segmentação com o maior número de dados disponíveis para a análise da IA. Com um histórico maior de engajamento, navegação e compras, a IA consegue realizar recomendações mais assertivas e isso se reflete nos cliques dos usuários. Os dados referentes aos descadastros dos e-mails estão apresentados a seguir.

Tabela 114 - Relatório de descadastrros

Segmento	Recomendação	Descadastrros	Taxa de Descadastrros
A – CE	Mais vendidos	27	0,81%
B – CE	Inteligência Artificial	34	1,03%
A – EU	Mais vendidos	13	0,39%
B- EU	Inteligência Artificial	6	0,18%
A – NU	Mais vendidos	35	1,08%
B – NU	Inteligência Artificial	23	0,68%

Fonte: autor (2023).

As taxas de descadastrro são influenciadas por muitos fatores, como por exemplo a quantidade e a frequência de e-mails já recebidos pelo usuário anteriormente, fato que não foi levado em consideração na construção das segmentações. Entretanto, o descadastrro também pode ter relação com o conteúdo do experimento. Recomendações desconexas com o perfil ou o desconforto do usuário em saber que seus dados comportamentais estão sendo tratados e utilizados na recomendação de produtos são fatores que podem ocasionar o descadastrro. De qualquer forma, os descadastrros não apresentaram um padrão, variando entre as comunicações da IA e Mais Vendidos.

Tabela 12 - Resultado do teste A/B - descadastrros

Segmentação	Descadastrro de A	Descadastrro de B	Aumento Relativo da taxa de descadastrro	p-valor	Diferença Significativa
CE	1,99%	2,44%	22,58%	0,4230	Não
EU	0,93%	0,42	-54,75%	0,0990	Não
NU	7,31%	4,79%	-34,42	0,1019	Não

Fonte: autor (2024).

As taxas de descadastro se mantiveram dentro das médias praticadas nos disparos recorrentes da Democrata.

#### 4.2 RESULTADOS DE CONVERSÃO PÓS CLIQUE

Nos disparos do experimento, após o clique, o usuário é direcionado para o link do produto recomendado caso tenha clicado em alguma das recomendações. Além disso, o usuário pode ser direcionado para a página inicial do site, caso tenha clicado no banner principal ou na logo da Democrata. Ele ainda pode cair em uma página com um catálogo de produtos caso tenha clicado em uma das categorias no menu do cabeçalho do e-mail. Por fim, há a possibilidade de o usuário ser direcionado para uma das redes sociais da Democrata, caso clique nos links do rodapé. Com exceção do último cenário, todos os dados de comportamentos do usuário nas páginas de destino são coletados através do Google Analytics 4. Os dados de conversão pós-clique são apresentados abaixo.

Tabela 53 - Relatório de pós-cliques

Segmento	Recomendação	Sessões	Adições ao carrinho	Transações	Receita
A - CE	Mais vendidos	95	3	2	R\$630,40
B - CE	Inteligência Artificial	110	3	1	R\$199,90
A - UE	Mais vendidos	71	1	0	R\$0,00
B - UE	Inteligência Artificial	73	2	0	R\$0,00
A - NU	Mais vendidos	41	2	0	R\$0,00
B - NU	Inteligência Artificial	59	2	0	R\$0,00

Fonte: autor (2023).

Apenas o segmento de compradores gerou transações nos disparos do experimento. Enquanto as recomendações de inteligência artificial geraram ao todo 7

adições ao carrinho e apenas 1 transação, os e-mails de recomendação de mais vendidos geraram 6 adições ao carrinho e 2 transações. Esperava-se que houvesse melhores resultados nos disparos, trazendo mais adições ao carrinho, mais transações e mais receita. Dessa forma, seria possível analisar com mais dados quais os atributos mais importantes na personalização e como cada uma das bases utilizadas se comporta. Como podemos ver nas tabelas a seguir, não houve diferenças significativas nas taxas de adição ao carrinho ou transações em nenhum dos segmentos.

Tabela 14 - Resultado do teste A/B - Adições ao Carrinho

Segmentação	Adições ao carrinho de A	Adições ao carrinho de B	Aumento Relativo da taxa de adição ao carrinho	p-valor	Diferença Significativa
CE	3,16%	2,73%	-13,64%	0,8560	Não
EU	1,41%	2,74%	94,52%	0,5739	Não
NU	4,88%	3,39%	-30,51%	0,7171	Não

Fonte: autor (2023).

Tabela 15 - Resultado do teste A/B - Transações

Segmentação	Transações de A	Transações de B	Aumento Relativo da taxa de transações	p-valor	Diferença Significativa
CE	2,11%	0,91%	-56,82%	0,4890	Não
EU	0,00%	0,00%	-	-	Não
NU	0,00%	0,00%	-	-	Não

Fonte: autor (2023).

Algumas possíveis explicações para os resultados obtidos abaixo da expectativa dizem respeito ao período do mês em que o disparo ocorreu, visto que historicamente na Democrata, quanto mais próximo do final do mês, menores são as taxas de conversão. Além disso, os disparos ocorreram no dia 25 de janeiro, feriado municipal em São Paulo, cidade que abriga a maior parte da base da Democrata. As taxas de engajamento e de conversão costumam cair em finais de semana e feriados

de acordo com o histórico da Democrata. Outras taxas relacionadas ao pós clique estão apresentadas a seguir.

Tabela 16 - Relatório de Sessões

Segmento	Recomendação	Sessões engajadas	Taxa de rejeição	Duração média da sessão
A - CE	Mais vendidos	80,0%	16,9%	2:15
B - CE	Inteligência Artificial	86,36%	10,9%	4:08
A - UE	Mais vendidos	73,24%	22,8%	2:15
B - UE	Inteligência Artificial	83,56%	14,9%	2:31
A - NU	Mais vendidos	85,36%	19,6%	2:24
B - NU	Inteligência Artificial	88,13%	13,8%	4:46

Fonte: autor (2023).

Olhando para os dados pós-clique, é possível criar diversas hipóteses para entender as diferenças e o impacto das recomendações realizadas por IA. As sessões engajadas representam aquelas sessões nas quais o usuário realizou interações significativas com o site. São consideradas sessões engajadas as sessões com mais de 10 segundos de duração, pelo menos 1 evento de conversão ou 2 visualizações de página/exibições de tela. Já a taxa de rejeição é uma métrica que mensura a quantidade de sessões em que não houve nenhuma interação no site. Isso quer dizer que o usuário clicou no produto recomendado e ao chegar no site, fechou a aba sem clicar em nada, rolar a página ou interagir com o produto.

Tabela 17 - Resultado de teste A/B - Sessões engajadas

Segmentação	Sessões engajadas de A	Sessões engajadas de B	Aumento Relativo das sessões engajadas	p-valor	Diferença Significativa
CE	80,00%	86,36%	7,95%	0,2253	Não
EU	73,24%	83,56%	14,09%	0,1298	Não
NU	85,37%	88,14%	3,24%	0,6899	Não

Fonte: autor (2024).

Podemos observar que apesar de termos tido um aumento nas sessões engajadas vindos das recomendações de IA, não podemos descartar a hipótese nula. Além das sessões engajadas, as taxas de rejeição também possuem variação, contudo, sem serem estatisticamente significativas. Apesar disso, é curioso que haja variação em todos os grupos. Para entender essa variação, olhamos também para a duração média da sessão. Infelizmente não foi possível capturar o dado de duração da sessão por usuário para calcular as variações e entender a relevância estatística, contudo, é curioso que haja tamanha variação nas médias em todos os grupos analisados. A duração média da sessão é tão importante pois além de ser uma etapa importante na maturação da decisão compra, o tempo que o usuário passa no site também alimenta o Einstein Recommendations com novos *insights* a respeito dos interesses do usuário, aperfeiçoando ainda mais as próximas recomendações.

A hipótese, olhando para todo o cenário de pós-clique, é que a recomendação de mais vendidos do site não foi tão assertiva e logo que o usuário entrou no site, ele já viu que a recomendação não era tão personalizada quanto ele esperava, diminuindo as sessões engajadas, elevando a taxa de rejeição e diminuindo o tempo médio de sessão. Além disso podemos olhar para algumas limitações existentes atualmente como por exemplo a numeração do calçado. Esse dado não é fornecido de forma explícita pelo usuário. Deste modo, a recomendação de mais vendidos do site não leva esse fator em consideração e pode recomendar um produto cuja numeração do usuário já está esgotada.

A inteligência artificial, por outro lado, consegue olhar para compras e navegações anteriores e levar a disponibilidade da numeração do usuário em consideração, mesmo que essa informação nunca tenha sido fornecida de forma

explícita. Limitações como essa tendem a aumentar a taxa de rejeição das recomendações baseadas no site.

## 5. DISCUSSÃO E CONCLUSÕES

Essa seção busca apresentar os resultados obtidos ao longo do experimento, respondendo aos objetivos geral e específicos, analisando as implicações e possíveis explicações para os dados observados.

### 5.1 ENGAJAMENTO E CONVERSÃO

Os resultados do experimento indicam que a recomendação de produtos personalizada por inteligência artificial (IA) não teve um impacto estatisticamente significativo nas taxas de engajamento em comparação com a recomendação padrão. Foi observado um aumento relativo nas taxas de clique sobre abertura, nas taxas de clique das recomendações, nas sessões engajadas, nos tempos médios de sessão, além de uma diminuição na taxa de descadastro para os emails personalizados pela IA. Contudo, nenhum desses aumentos foi estatisticamente significativo para indicar uma melhor performance por conta da recomendação.

Além disso, outro fator importante no experimento, é que não houve incremento nas taxas de conversão pós-clique. As sessões no site com origem vindas dos e-mails de recomendação por Inteligência Artificial não tiveram melhores taxas de adição ao carrinho, transações ou geraram mais receita.

Isso sugere que, embora a IA possa ter sido capaz de gerar recomendações mais relevantes para os usuários, essas recomendações não necessariamente levam a uma maior receita imediata. Isso pode ser devido a uma série de fatores, incluindo limitações nos dados coletados, a apresentação das recomendações no email e expectativas e preferências individuais dos usuários. Contudo, é importante reforçar que, com o aumento relativo nas sessões engajadas geradas e com o aumento do tempo médio de sessão, a IA também recebe um incremento nos dados coletados pela plataforma. De acordo com Ludewig e Jannach (2018) sessões mais longas podem fornecer mais informações sobre as preferências e comportamentos do usuário, o que pode resultar em recomendações mais precisas no futuro.

### 5.2 DIFERENÇA DE RESULTADOS ENTRE SEGMENTOS



Neste estudo, foram analisados três segmentos distintos: Compradores Engajados (CE), Usuários Engajados (UE) e Novos Usuários (NU). Cada um desses segmentos apresentou comportamentos e respostas diferentes às recomendações de produtos.

#### 5.2.1 Compradores Engajados (CE)

O segmento de compradores engajados incluía usuários com histórico de compra no site da Democrata. Isso significa que esse era o segmento que possuía o maior número de dados disponíveis para análise da IA, possibilitando recomendações mais assertivas. Essa base já era considerada engajada, segundo Bi et al (2021) usuários com um maior histórico de engajamento por e-mail tendem a ter taxas de abertura e cliques mais altas. Portanto, já esperava-se de antemão maiores taxas de abertura e clique.

Como esperado, esse foi o segmento que mostrou a maior taxa de cliques. Mesmo já tendo uma taxa bastante alta na recomendação padrão, teve incremento relativo na personalização por IA. Apesar de não possuir relevância estatística, quando as recomendações foram geradas pela IA, esse segmento apresentou melhoras relativas. Isso sugere que a IA foi capaz de gerar recomendações mais assertivas para este grupo, possivelmente devido ao maior histórico de engajamento, navegação e compras disponível para análise

Mesmo se tratando da base com maior número de dados disponíveis para a análise da plataforma, não houve incremento na receita, nas adições ao carrinho ou nas transações. Houveram 3 compras mas duas delas aconteceram nas recomendações de produtos mais vendidos e somente uma na recomendação de IA. O resultado esperado era que houvesse mais compras e um incremento significativo de conversão, adição ao carrinho e receita nas recomendações de IA, principalmente quando diz respeito a essa segmentação específica e, apesar de ter sido a única segmentação que realizou compras, o volume foi considerado baixo.

Uma explicação possível para o baixo número de transações relacionados ao disparo é o período do mês em que ele ocorreu que, além de ser feriado municipal em São Paulo, cidade que abriga grande parte da base da Democrata, também era final de mês, período em que o poder de compra já é menor.

### 5.5.2 Usuários Engajados (UE)

O segmento de usuários engajados incluía usuários sem histórico de compra no site da Democrata mas que abrem emails. Esse também era um segmento que possuía o grande número de dados disponíveis para análise da IA. Essa base era considerada engajada e portanto, esperava-se de antemão boas taxas de abertura e clique contudo, por ser uma base de não compradores, esperava-se menos compras uma vez que, segundo Bilovodska e Peretskova (2023), existem diversas barreiras para a primeira compra no usuário no comércio eletrônico como por exemplo incertezas quanto ao prazo de entrega, custo de frete e formas de pagamento. Para os Usuários Engajados, não houve nas taxas de abertura ou clique entre as recomendações da IA e as recomendações de produtos mais vendidos.

O aumento relativo observado nas taxas, principalmente no que se refere a clique, parece ser bastante relevante apesar de não ter validação estatística, Contudo, vale lembrar que o teste-t aplicado também possui limitações e o fato de não haver diferenças estatisticamente significativas, não significa necessariamente que não há diferença entre os grupos, apenas que não temos evidências suficientes para rejeitar a hipótese nula. Além disso, o p-valor não nos diz nada sobre o tamanho ou a importância prática da diferença. Uma diferença pode ser estatisticamente significativa, mas não necessariamente importante do ponto de vista prático ou vice-versa.

A base de Usuário Engajados não realizou nenhuma compra no site e os dados a respeito de adição ao carrinho são bastante limitados. Assim, como na segmentação anterior, as principais hipóteses sobre os resultados ruins pós-clique têm relação com o período em que os disparos foram realizados além das barreiras de primeira compra do usuário.

### 5.5.3 Novos Usuários (NU)

O segmento de novos usuários incluía usuários que entraram na base a 30 dias ou menos. Esse é um segmento que possui pouco ou nenhum dado. Em termos de engajamento, essa é uma base bastante heterogênea na qual alguns usuários abrem todos os e-mails e outros nunca sequer abriram um. Nesse cenário, é difícil saber o

que esperar em termos de abertura e cliques. Contudo, espera-se taxas mais baixas do que os segmentos anteriores. Essa expectativa se confirmou.

Para os Novos Usuários, também não houve diferenças significativas nas taxas de abertura, cliques ou descadastro entre as recomendações da IA e as recomendações de produtos mais vendidos. Esses são os resultados esperados visto que esses usuários têm um histórico limitado de engajamento e compras, tornando mais difícil para a IA gerar recomendações altamente personalizadas.

Assim como as segmentações anteriores, os Novos Usuários também não realizaram nenhuma compra e tiveram um baixo nível de adição ao carrinho. As hipóteses são as mesmas apresentadas anteriormente.

#### 5.5.4 Segmentos Agrupados

Para contribuir com a análise e buscar uma visão diferente, olhei também para os segmentos de forma agrupada. Assim repliquei os testes A/B olhando para as recomendações de IA e recomendações de Mais Vendidos sem levar em consideração a qual segmento os usuários pertenciam. Assim, tivemos os seguintes dados analisados e resultados.

Tabela 18 - Relatório Agrupado

Recomendação	Enviados	Aberturas	Cliques	Cliques em Recomendações
Mais Vendidos	9.909	3.231	203	158
Inteligência Artificial	10.003	3.297	234	201

Fonte: autor (2024).

Tabela 19 - Resultado de teste A/B - Agrupado

Testes	Cliques de A	Cliques B	Aumento Relativo dos Cliques	p-valor	Diferença Significativa
Cliques	203	234	12,96%	0,1877	Não
Cliques em Recomendações	158	201	24,67%	0,0323	Sim

Fonte: autor (2024).

Através desse teste, quando não consideramos nenhuma segmentação, há diferença significativa entre as recomendações de IA e Mais Vendidos do site. Esse resultado com mais usuários envolvidos, somado as melhoras aparentes nas taxas de conversão de todas as segmentações ao longo do experimento, indica resultados promissores em favor da inteligência artificial. Novos estudos utilizando bases maiores de disparo podem contribuir para aprofundar o conhecimento e entender esses resultados.

### 5.3 LIMITAÇÕES E OPORTUNIDADES

Ao longo do experimento, algumas limitações foram encontradas. Uma limitação importante que foi identificada é a falta de informação explícita sobre a numeração do calçado preferida pelo usuário. Atualmente, esse campo não é coletado de forma explícita. Isso pode ter impactado a relevância das recomendações uma vez que a experiência do usuário é bastante frustrada ao clicar em um produto recomendado especialmente para ele e não possuir a sua numeração.

Por outro lado, a IA é capaz de levar em consideração as compras e navegações anteriores do usuário para inferir a numeração preferida, mesmo que essa informação não tenha sido fornecida explicitamente. Isso sugere que a IA tem o potencial de superar algumas das limitações das recomendações baseadas em produtos mais vendidos e pode oferecer uma experiência mais personalizada e relevante para o usuário.

Outra limitação encontrada é relacionada a importação de catálogo de produtos para a plataforma. Atualmente, os produtos esgotados não são importados para o estoque. Por um lado, isso impede a plataforma de recomendar um produto totalmente esgotado, mas por outro lado, também a impede de utilizar esses produtos para analisar o perfil de consumo do usuário. Um usuário que navegou ou comprou um produto esgotado, não terá essa informação levada em consideração pois a IA “não conhece” esse produto. Por fim, seria interessante replicar o experimento utilizando bases de usuários maiores e em outros períodos do ano para não coincidir com feriados e para ocorrer em um momento mais inicial do mês. Dessa forma, além de conseguir atingir valores estatisticamente significativos, é provável que haja melhores taxas de conversão e um maior volume de compras, possibilitando análises mais profundas.

## REFERÊNCIAS

ALMASRI, Abdelbaset. *et al.* Intelligent Tutoring Systems Survey for the Period 2000-2018. **International Journal of Academic Engineering Research (IJAER)**, Gaza, Palestine, v. 3, p. 21–37, mai. 2019. Disponível em: < <https://bit.ly/49w22iq>> Acesso em: 5 fev. 2024.

AL-ZYOUN, Mohammad Fahmi. Does social media marketing enhance impulse purchasing among female customers case study of Jordanian female shoppers. **Journal of Business e Retail Management Research**, Jordânia, p. 135-151. v. 13, n. 2, dez. 2018. Disponível em: < <https://bit.ly/49uQ8p7>>. Acesso em: 13 jul. 2023.

AKIMOVA, Olga. **Tracking user behavior on the web for digital marketing personalization with Salesforce**. 2019. Monografia (Programa em Negócios da Informação e Tecnologia), Haaga-Helia University of Applied Sciences. Helsínque, 2019. Disponível em: <<https://bit.ly/49sILP8>>. Acesso em: 13 jul. 2023

BAUMGARTEN, Karina. **Sistema de Recomendação Progressiva Para E-mails De Lembrete De Carrinho Abandonado**. 2021. Monografia (Especialista em Ciência de Dados e Suas Aplicações) - Universidade Tecnológica Federal Do Paraná Departamento De Informática, Curitiba, 2021. Disponível em: < <https://bit.ly/3wIKMy0>>. Acesso em: 11 ago. 2023.

BERNARDES, Marília. **Um Estudo Das Ações De Marketing De Relacionamento Na Ótica do Cliente: O caso Magazine Luiza. Mestrado**. 2009. Dissertação (Mestrado Profissionalizante em Administração) – Faculdades Integradas de Pedro Leopoldo. Belo Horizonte, 2009.

BHAGAT, Mosami; CHATUR, Prashant. A Study on Product Recommendation System based on Deep Learning and Collaborative Filtering. *In*: THIRD INTERNATIONAL CONFERENCE ON ADVANCES IN ELECTRICAL, COMPUTING, COMMUNICATION AND SUSTAINABLE TECHNOLOGIES, 2023, Bhilai. **Anais [...]**. Bhilai, India: ICAECET, p. 1–5, 5 jan. 2023. Disponível em: <https://bit.ly/3we8tsk>>. Acesso em: 14 jul. 2023.

BI, K. *et al.* Leveraging User Behavior History for Personalized Email Search. **Proceedings of the Web Conference 2021**, p. 2858–2868, 19 abr. 2021. Acesso em < <http://bit.ly/3O AQFOg>> acesso em: 15 jan. 2024

BOKDE, Ujjwal.; SESHAN, Subramaniam. To study the impact of digital marketing on purchase decision of youth in Nagpur City. *In*: INTERNATIONAL JOURNAL OF ADVANCE RESEARCH, IDEAS AND INNOVATIONS IN TECHNOLOGY, v. 5, n.3, 2019, Nagpur. **Anais [...]**. Nagpur: IJAR IIT, 2019. Disponível em: < <https://bit.ly/3wjfPul>>. Acesso em: 5 ago. 2023.

BRASIL. Lei nº 13.709, de 14 de agosto de 2018. Institui a Lei Geral de Proteção de Dados (LGPD). Brasília, DF: Presidência da República, 2018. Disponível em: < <https://bit.ly/3UzYJT5>>. Acesso em: 8 out. 2023.

CASTELO, Noah; BOS, Marteen; LEHMANN, Donald. Task-Dependent Algorithm

Aversion. **Journal of Marketing Research**, Estados Unidos, v. 56, n. 5, p. 809–825, jul. 2019. Disponível em: <<https://bit.ly/42zE57K>>. Acesso em: 13 jul. 2023.

CHU, Wei; PARK, Seung-Taek. Personalized recommendation on dynamic content using predictive bilinear models, **Proceedings of the 18th international conference on World wide web**, Santa Clara, Estados Unidos, p. 691–700, abr. 2009. Disponível em: <<https://bit.ly/3HUIOHK>>. Acesso em: 3 ago. 2023.

Einstein Recommendations Scenarios. **Salesforce**. Disponível em: <<https://bit.ly/3ujlD5D>>. Acesso em: 7 out. 2023.

FELFERNIG, Alexander; BURKE, Robin. Constraint-based recommender systems. **Conference: 10th International Conference on Electronic Commerce**, Innsbruck, Austria, p. 19-22, ago. 2008. Disponível em: <<https://bit.ly/48deORS>>. Acesso em: 4 ago. 2023.

GABRANI, Goldie; SABHARWAL, Sangeeta; SINGH, Viomesh. Kumar. Artificial Intelligence Based Recommender Systems: A Survey. **Communications in Computer and Information Science**, Springer, Singapura, p. 50–59, jul. 2017. Disponível em <<https://bit.ly/3wccehO>> Acesso em: 25 dez. 2023.

GREEN, Brian. Patrick. Ethical Reflections on Artificial Intelligence. **Scientia et Fides**, [S. l.], v. 6, n. 2, p. 9–31, 2018. Disponível em: <<https://bit.ly/3OEvgE5>>. Acesso em: 13 ago. 2023.

GURSOY, Dogan *et al.* Consumers acceptance of artificially intelligent (AI) device use in service delivery. **International Journal of Information Management**, v. 49, n. 49, p. 157–169, dez. 2019. Disponível em: <<https://bit.ly/499QQbs>>. Acesso em: 13 ago. 2023.

JAIN, Geetika, e. *al.* Hyper-personalization – fashion sustainability through digital clienteling, **Research Journal of Textile and Apparel**, v. 22, n. 4, p. 320-334, jun. 2018. Disponível em: <<https://bit.ly/3SQ3MO2>>. Acesso em: 7 ago. 2023.

JOINSON, Adam. Personalized salutation, power of sender and response rates to Web-based surveys. **Computers in Human Behavior**, v. 23, n. 3, p. 1372–1383, mai. 2007. Disponível em: <<https://bit.ly/3UGeVCF>>. Acesso em 13 jul. 2023.

JONES, Andrew. **Marketing Personalization: Maximizing Relevance and Revenue**. Califórnia: VB Insight, 2015. Disponível em: <<https://bit.ly/3SxSigL>>. Acesso em: 14 ago. 2022.

LINDEN, Greg.; SMITH, Brent; YORK, J.. Amazon.com recommendations: item-to-item collaborative filtering. **IEEE Internet Computing**, v. 7, n. 1, p. 76–80, jan. 2003. Disponível em <<https://bit.ly/3HVbDUo>>. Acesso em: 20 nov. 2023.

LONGONI, Chiara.; CIAN, Luca. Artificial Intelligence in Utilitarian vs. Hedonic Contexts: the “Word-of-Machine” Effect. **Journal of Marketing**, v. 86, n. 1, p. 91-108, nov. 2020. Disponível em: <<https://bit.ly/3HSbot0>>. Acesso em 13 jul. 2023.

LONGONI, Chiara; CIAN, Lucca. When Do We Trust AI's Recommendations More Than People's? **Harvard Business Review**. 14 out. 2020. Disponível em: <<https://bit.ly/42vFI6x>>. Acesso em: 13 jul. 2023.

LUDERMIR, Teresa. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, São Paulo, v. 35, n. 101, p. 85–94, abr. 2021. Disponível em: <<https://bit.ly/4972xQd>>. Acesso em 13 jul. 2023

LUDEWIG, Malte; JANNACH, Dietmar. Evaluation of session-based recommendation algorithms. **User Modeling and User-Adapted Interaction**, v. 28, n. 4-5, p. 331–390, 1 out. 2018. Disponível em: <<https://bit.ly/3HSy7oY>>. Acesso em 5 jan. 2024.

MURALI, Mayank; VISHNU, T G.; VICTOR, Nancy. A Collaborative Filtering based Recommender System for Suggesting New Trends in Any Domain of Research. *In*: 5TH INTERNATIONAL CONFERENCE ON ADVANCED COMPUTING & COMMUNICATION SYSTEMS, 2019, Coimbatore. **Anais [...]**. Coimbatore: ICCACS, p. 550-553, 15 mar. 2019. Disponível em: <<https://bit.ly/3uq0p7h>> Acesso em 10 jan. 2024.

NEVES, Felipe.; DUDUCHI, Marcelo. Testes A/B como uma das estratégias para inovação em produtos digitais: uma análise bibliométrica. *In*: SIMPÓSIO DE EXCELENCIA EM GESTÃO E TECNOLOGIA, 2019, Rio de Janeiro. **Anais [...]**. Rio de Janeiro: SEGet, 2019.

BILOVODSKA, Olena.; PORETSKOVA, Mariia. Barriers to online purchase: case study consumer behaviour in fashion industry e-commerce. **Економічний часопис Волинського національного університету імені Лесі Українки**, v. 2, n. 34, p. 102–112, 13 set. 2023.

PARK, Jaeseung *et al.* Impact on recommendation performance of online review helpfulness and consistency. **Data Technologies and Applications**, v. 5, n. 2, p: 199-221, abr. 2023. Disponível em: <<https://bit.ly/3HT3krZ>>. Acesso em: 5 ago. 2023.

PRATHAMA, Frans, *et al.*, (2021). Personalized recommendation by matrix co-factorization with multiple implicit feedback on pairwise comparison. *Computers & Industrial Engineering*, v. 152, n. 1, dez. 2020. Disponível em: <<https://bit.ly/3SCmqrk>>. Acesso em: 3 set. 2023.

RIZZO, Esmeralda. **Uma Análise Comparativa entre o Marketing de Massa e o “One to One” Marketing, no Cenário de Empresas Competitivas**. São Paulo, jan. 2006. Disponível em: <<https://bit.ly/49tMYIz>> Acesso em: 31 jul. 2022.

SINGH, Gyanendra.; SINGH, Himanshu.; SHRIWASTAV, Sonika. Improving Email Marketing Campaign Success Rate Using Personalization. *Advances in Analytics and Applications*. Springer Proceedings in Business and Economics, *In*: LANA, Arnab Kumar (ed). **Advances in Analytics and Applications**. Singapura: Springer, 2018. p. 77-83.

SOHN, Kwonsang.; KWON, Ohbyung. Technology acceptance theories and factors

influencing artificial intelligence-based intelligent products. **Telematics and Informatics**, v. 47, abr. 2020. Disponível em: <<https://bit.ly/3SSGkja>>. Acesso em: 15 set. 2023.

The value of getting personalization right—or wrong—is multiplying. **McKinsey&Company [online]**. 12 nov. 2021. Disponível em <<https://bit.ly/3urBIY4>> Acesso em 12 ago. 2023.

TIMPONI, Luciana. **Atributos de personalização no canal de e-mail marketing e a resposta do consumidor na sua percepção da marca**. 2022. Monografia (Graduação em Administração) – Departamento de Ciências Administrativas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2022. Disponível em: <<https://bit.ly/3ODfQ2E>>. Acesso em: 2 set. 2023.

TRESPALACIOS, Jesús; PERKINS, Ross. Effects of Personalization and Invitation Email Length on Web-Based Survey Response Rates. **TechTrends**, v. 60, n. 4, p. 330–335, 4 abr. 2016. Disponível em: <<https://bit.ly/3SB075j>>. Acesso em: 13 jul. 2023.

UGONNA, Ikechukwu *et al.* Effects of Online Marketing on the Behaviour of Consumers in Selected Online Companies in Owerri, Imo State -Nigeria. **International Journal of Business and Management Invention**, Nsukka, Nigeria, v. 6, n. 6, p. 32–43, jun. 2017. Disponível em: <<https://bit.ly/3OFGhVA>>. Acesso em 13 jul. 2023.

WATTAL, Sunil, *et al.* Examining the Personalization-Privacy Tradeoff – an Empirical Investigation with Email Advertisements, **Managment Science**, Charlottesville, 2005. Disponível em: <<https://bit.ly/42yILvI>>. Acesso em: 31 jul. 2023.

ZHAO, Xuesong. A Study on E-commerce Recommender System Based on Big Data. *In: INTERNATIONAL CONFERENCE ON CLOUD COMPUTING AND BIG DATA ANALYSIS*, 2019, Chengdu. **Anais [...]**. Chengdu, China: ICCCBDA, p. 222-226, 12-15 abr. 2019. Disponível em: <<https://bit.ly/48hi3rA>>. Acesso em: 1 set. 2023.

ZHOU, Wen.; HAN, Wenbo. Personalized recommendation via user preference matching. **Information Processing & Management**, v. 56, n. 3, p. 955–968, mai. 2019. Disponível em: <<https://bit.ly/3HSgvJZ>>. Acesso: 10 ago. 2023.